



UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE

Programa de Doctorado en Criminología

TESIS DOCTORAL

Dimensión espacial del perfilado geográfico: debilidades y oportunidades

Tesis Doctoral presentada por

Daniel Salafranca Barreda

Director: Dr. D. Samuel Rodríguez Ferrández

Codirector: Dr. D. Jorge Mateu Mahiques

Elche, 2024

La presente Tesis Doctoral, titulada “*Dimensión espacial del perfilado geográfico: debilidades y oportunidades*” se presenta bajo la modalidad de tesis convencional con los siguientes indicios de calidad:

- Salafranca, D., Rodríguez, S., y Mateu, J. (2020). El perfil geográfico: comportamiento y adaptación al medio. *International E-Journal of Criminal Science*, 15, 1–27.” <https://ojs.ehu.eus/index.php/inecs/article/view/21533> (véase ANEXO F);
- Salafranca Barreda, D., Yaksic, E. (2022) Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders. *Journal Police Criminal Psychology*. <https://doi.org/10.1007/s11896-022-09561-3> (véase ANEXO D)
- Salafranca Barreda, D. (2021), The application of Newton and Swoope's geographical profile to serial killers. *Journal of Investigative Psychology and Offender Profiling*, 18: 68-78. <https://doi.org/10.1002/jip.1566> (véase ANEXO E)
- Salafranca Barreda, D. (2023). Humanos versus Algoritmos: Diferencias en la eficacia en la perfilación geográfica criminal. *Revista Española De Investigación Criminológica*, 21(1), e797. <https://doi.org/10.46381/reic.v21i1.797> (véase ANEXO C)
- Daniel Salafranca Barreda, Diego J. Maldonado Guzman & Patricia Saldaña Taboada (2022), Crime beyond the edge: development of a tool to correct the edge effect on crime count. *Annals of GIS*, 28:3, 279-292, <https://doi.org/10.1080/19475683.2022.2052748> (véase ANEXO G)



El Dr. D. Samuel Rodríguez Ferrández”, director y el Dr. D. Jorge Mateu Mahiques, codirector de la Tesis Doctoral titulada “*Dimensión espacial del perfilado geográfico: debilidades y oportunidades*”

INFORMA/N:

Que D. Daniel Salafranca Barreda, ha realizado bajo nuestra supervisión el trabajo titulado “*Dimensión espacial del perfilado geográfico: debilidades y oportunidades*” conforme a los términos y condiciones definidos en su Plan de Investigación y de acuerdo con el Código de Buenas Prácticas de la Universidad Miguel Hernández de Elche, cumpliendo los objetivos previstos de forma satisfactoria para su defensa pública como tesis doctoral.

Lo que firmo/firmamos para los efectos oportunos, en a dede 2024.

Director/a de la tesis

Dr. D./ Samuel Rodríguez Ferrández

Codirector/a de la tesis

Dr. D./ D. Jorge Mateu Mahiques



El Dr. D. Fernando Miró Llinares, Coordinador del Programa de Doctorado en Criminología de la Universidad Miguel Hernández de Elche.

INFORMA:

Que D. Daniel Salafranca Barreda “ha realizado bajo la supervisión de nuestro Programa de Doctorado el trabajo titulado “*Dimensión espacial del perfilado geográfico: debilidades y oportunidades*”, conforme a los términos y condiciones definidos en su Plan de Investigación y de acuerdo al Código de Buenas Prácticas de la Universidad Miguel Hernández de Elche, cumpliendo los objetivos previstos de forma satisfactoria para su defensa pública como tesis doctoral.

Lo que firmo para los efectos oportunos, en a de de 2024.

Prof. Dr. D. Fernando Miró Llinares

Agradecimientos

Quisiera expresar mi más profundo y sincero agradecimiento a cada persona que, de diversas formas, ha colaborado y me ha brindado su apoyo y compañía en esta travesía.

En primer lugar, deseo expresar mi más profunda gratitud a mis directores, el Dr. D. Samuel Rodríguez Ferrández y el Dr. D. Jorge Mateu Mahiques, por la confianza, paciencia y el apoyo incondicional que han depositado en mí. Agradezco profundamente su asistencia esencial e incalculable, su asesoramiento detallado y los conocimientos profundos que han compartido durante el desarrollo de esta investigación.

Al Centro Crímina de la Universidad Miguel Hernández, a su director, el Dr. D. Fernando Miró Llinares y a todo su personal que me acompañaron y dieron todo su apoyo.

A mis amigos, Diego Maldonado y Patricia Saldaña, por su apoyo constante y su generosa ayuda a lo largo de este proceso. Su presencia y contribuciones han sido invaluable. Gracias de todo corazón por estar siempre ahí.

Gracias a mi mujer y mis hijos, Berta y Daniel, a quienes, de una manera especial, quiero dedicarles este trabajo; gracias por vuestro apoyo fiel y cariño constante, por vuestra generosidad y sacrificio, para que yo pudiera disponer de tiempo, y así, poder alcanzar mi meta.

A mis padres.

Índice

RESUMEN	1
ABSTRACT.....	3
INTRODUCCIÓN	5
Estructura de la tesis	8
PARTE I PERFIL GEOGRÁFICO.....	11
Capítulo 1 ANTECEDENTES TEÓRICOS.....	12
Capítulo 2 PERFIL GEOGRÁFICO	25
1. Concepto	25
2. Condiciones y limitaciones.....	29
3. Dimensiones.....	42
3.1 Espacial	42
3.2 Temporal.....	43
3.3 Cognitiva.....	45
Capítulo 3 SISTEMAS DE INFORMACIÓN GEOGRÁFICA	47
3.1 SIG Especializado en Perfilado Geográfico.	50
Rigel.....	51
Dragnet.....	76
CrimeStat	86

	xii
Predator	97
Otras herramientas de Perfilado geográfico.....	99
3.2 Elementos.....	105
Área de actuación.....	105
Puntos de anclaje y conjuntos de ubicación delictiva.....	110
3.3 Medidas de precisión	112
Capítulo 4 ESTRATEGIAS DE PERFIL GEOGRÁFICO	116
4.1 Estrategias de distribución espacial	116
La media aritmética.....	118
La media geométrica.....	120
El centro de la distancia mínima.....	123
Fortaleza y debilidades modelo	125
4.2 Estrategias de probabilidad de distancia.....	126
4.3 Estrategias de dispersion espacial.....	128
Envolverte convexa mínima (convex hull polygon).....	128
Modelo Newton-Swoope	129
Círculo mínimo	130
Diagrama de Venn	133
Elipse de desviación estándar	136
Priorización del centroide aritmético	139
Rectángulo delimitador mínimo	141
PARTE II ESTUDIO EMPÍRICO I	143
Capítulo 5 ESTUDIO EMPÍRICO.....	144

5.1. Objetivos	144
5.2. Hipótesis	147
Capítulo 6 MÉTODO	148
6.0 Grupo delincente (Delincuentes de Homicidio en Serie)	150
6.1 Análisis de datos históricos de asesinos seriales.....	154
6.2 Base de datos para Investigación	158
6.3 Set de datos	161
6.4 Revisión sistemática de los datos preliminares.....	162
6.5 Estudio descriptivo de la muestra	166
6.6 Variables	169
6.7 Ficha de variables	170
6.8 Estudio Instrumental de caso	174
6.8.1 Selección y definición del caso.....	175
6.8.2 Datos caso Peter Sutcliffe.....	176
Capítulo 7 OPTIMIZACIÓN PERFILADO GEOGRÁFICO (GEO-SCRIPT).....	178
7.0 Sistema de Información Geográfica (SIG) en el software QGIS.....	183
7.1. Lenguaje de programación PYTHON y R.....	184
7.2 Desarrollo Complemento.....	186
7.2.1 Estructura de algoritmo en diagrama de flujo.....	188
7.2.1 Introducción datos.....	190
7.2.2 Cuadro de dialogo	191
7.2.3 Transformación de coordenadas geográficas a proyectadas	192
7.2.4 Comprobación Merodeador / Viajero	193

7.2.5 Estrategia distribución espacial (centro mínima distancia, centroide).....	194
7.2.6 Estrategia de distribución de dispersión (Diagrama de Venn).....	195
7.2.7 Estrategia de distribución de dispersión (Círculo de Canter)	196
7.2.8 Estrategia de distribución de dispersión (Círculo centro mínima distancia)	197
7.2.9 Estrategia de distribución de dispersión (Rectángulo área mínima limitación)	198
7.2.9a Estrategia de distribución de dispersión (Envolvente convexa)	199
7.2.9c Estrategia de distribución de dispersión (Elipse).....	201
7.2.9d Estrategia de distancia de probabilidad.....	202
PARTE III ESTUDIO EMPÍRICO II [PROCEDIMIENTO].....	203
Capítulo 8 HUMANOS VERSUS ALGORITMOS: DIFERENCIAS EN LA EFICACIA EN LA PERFILACIÓN GEOGRÁFICA CRIMINAL.	204
Resumen.....	204
Capítulo 9 EVALUACIÓN DE LAS ESTRATEGIAS DE DISPERSIÓN UTILIZADAS PARA LOCALIZAR A LOS DELINCUENTES DE HOMICIDIOS EN SERIE.....	206
Resumen.....	206
Capítulo 10 LA APLICACIÓN DEL PERFIL GEOGRÁFICO DE NEWTON Y SWOOPE.....	207
Resumen.....	207
Capítulo 11 MODIFICACIÓN DEL ALGORITMO DEL MÉTODO DE ANÁLISIS GEOFORENSE DE NEWTON Y SWOOPE.....	208
Resumen.....	208

Introducción	208
Estrategias de perfil geográfico	212
Centrografía y geografía	216
Medidas de centralidad (centro medio).....	218
Medidas de centralidad (centro de mínima distancia)	221
Metodología	223
Datos	225
Resultados	228
Discusión.....	230
Capítulo 12 MERODEADORES Y VIAJEROS.....	235
Resumen.....	235
Introducción	236
Clasificación	241
Modelo Canter y Larkin (Circle Theory of Environmental Range)	242
Modelo Warren (Convex Hull Polygon).....	244
Merodeador o Viajero	249
Objetivos e hipótesis	254
Objetivos	254
Hipótesis	255
Metodo	255
Datos	256
Variables	258
Instrumento	261

Aprendizaje automático supervisado	261
Modelo de regresión logística.....	263
Modelo Redes Neuronales Artificiales	266
Resultados	287
Regresión Logística	288
Redes Neuronales.....	300
Métricas de evaluación comparadas	324
Resultados Caso Instrumental / Fuera de muestra	355
Conclusiones	362
Capítulo 13 FUNCIONES DECAIMIENTO DE LA DISTANCIA.....	370
Resumen.....	370
Introducción.....	371
Modelos matemáticos	380
Funciones de decaimiento de la distancia.....	384
Limitaciones.....	397
Conclusiones	404
Capítulo 14 EL PERFIL GEOGRÁFICO: COMPORTAMIENTO Y ADAPTACIÓN AL MEDIO.....	409
Resumen.....	409
Capítulo 15 EXPLORANDO LA CONSISTENCIA DIRECCIONAL	411
Resumen.....	411
Introducción.....	412
Datos Circulares e Instrumento.....	418

Software especializado.....	419
Objetivos e hipótesis.....	420
Metodología.....	421
Datos e instrumento	421
Procedimiento	424
Resultado.....	431
Conclusiones	437
Capítulo 16 DISCUSIÓN Y CONCLUSIONES	441
REFERENCIAS BIBLIOGRÁFICAS.....	459
ANEXOS.....	508
ANEXO A DELINCUENTES DE HOMICIDIO EN SERIE (SHOs).....	509
ANEXO B CUESTIONARIO DATOS.....	513
ANEXO C INDICIO DE CALIDAD DE LA TESIS DOCTORAL (ARTÍCULO CIENTÍFICO)	515
ANEXO D INDICIO DE CALIDAD DE LA TESIS DOCTORAL (ARTÍCULO CIENTÍFICO)	534
ANEXO D.1 INDICIO DE CALIDAD DE LA TESIS DOCTORAL (TRANSCRIPCIÓN ARTÍCULO CIENTÍFICO)	552
ANEXO E INDICIO DE CALIDAD DE LA TESIS DOCTORAL (ARTÍCULO CIENTÍFICO)	588

ANEXO F INDICIO DE CALIDAD DE LA TESIS DOCTORAL (ARTÍCULO CIENTÍFICO)	610
ANEXO G INDICIO DE CALIDAD DE LA TESIS DOCTORAL (ARTÍCULO CIENTÍFICO)	622
ANEXO H CÓDIGO FUENTE REDES NEURONALES.....	650
ANEXO I CÓDIGO USADO EN R PARA RAYLEIGH'S TEST Y MOORE.....	655
ANEXO J ESTRUCTURA DEL ALGORITMO EN DIAGRAMAS DE FLUJO.....	688

RESUMEN

El perfil geográfico es una técnica de investigación criminal que analiza las ubicaciones de una serie de delitos para determinar el área más probable de residencia del delincuente. Esta técnica se revela como una herramienta esencial, permitiendo que los investigadores adquieran una comprensión más detallada del comportamiento delictivo y contribuyendo significativamente tanto a la identificación del delincuente como a la formulación de estrategias de investigación más enfocadas y efectivas. Sin embargo, a pesar de su gran potencial, el perfilado geográfico enfrenta ciertas limitaciones, principalmente debido a suposiciones simplistas que pueden complicar su aplicación práctica y validación en casos individuales.

El objetivo de la presente tesis doctoral es analizar la metodología de la elaboración de perfiles geográficos, identificar dónde se pueden encontrar dificultades y hacer sugerencias sobre cómo mejorar esta elaboración. En concreto, se pone especial énfasis en aquellos aspectos que serán de mayor relevancia y accesibilidad en una investigación. Se realiza una exploración profunda de la compleja interacción de la dimensión espacial y la movilidad entre los delincuentes, centrándose, en particular, en los delincuentes homicidas en serie (SHOs).

Además de este objetivo, la tesis cuestiona la eficacia de las heurísticas humanas en la simplificación de problemas complejos en comparación con las técnicas actuariales. También se explora en estrategias de distribución de dispersión y se propone un modelo de perfilado geográfico basado en la teoría de conjuntos, con el propósito de identificar áreas iniciales de búsqueda de SHOs. Se aborda en detalle la metodología propuesta por Newton y Swoope, resaltando sus vulnerabilidades y proponiendo mejoras mediante la incorporación del algoritmo de Weiszfeld. Además, se examina la relevancia de distintas medidas de distancia, como la

euclidiana, Manhattan y el algoritmo Dijkstra, en el contexto de la *journey to crime*. A continuación, la tesis evalúa la consistencia de la direccionalidad de las series de los SHOs mediante estadística circular y finalmente, se propone una alternativa al efecto de clasificar delincuentes merodeadores y viajeros, superando las limitaciones de los softwares actuales mediante técnicas de aprendizaje automático.

En resumen, esta tesis doctoral presenta una serie de conceptos y enfoques que pueden contribuir significativamente al avance investigativo en el ámbito del perfilado geográfico. Sin embargo, aún persisten desafíos y preguntas pendientes. Estas cuestiones, sin duda, demandarán la atención y análisis detallado de los investigadores en el futuro.

ABSTRACT

Geographic profiling is a criminal investigation technique that analyses the locations of a number of crimes to determine the most likely area of residence of the offender. This technique is proving to be an essential tool, allowing investigators to gain a more detailed understanding of criminal behaviour and contributing significantly to both the identification of the offender and the formulation of more focused and effective investigative strategies. However, despite its great potential, geographical profiling faces certain limitations, mainly due to simplistic assumptions that can complicate its practical application and validation in individual cases.

The aim of this PhD thesis is to analyse the methodology of geographical profiling, to identify where difficulties can be found and to make suggestions on how to improve geographical profiling. In particular, special emphasis is placed on those aspects that will be of most relevance and accessibility in research. An in-depth exploration of the complex interplay of the spatial dimension and mobility among offenders is undertaken, focusing in particular on serial homicidal offenders (SHOs).

In addition to this objective, the thesis questions the effectiveness of human heuristics in simplifying complex problems in comparison to actuarial techniques. It also explores dispersion distribution strategies and proposes a geographical profiling model based on set theory, with the aim of identifying initial search areas for SHOs. The methodology proposed by Newton and Swoope is discussed in detail, highlighting its vulnerabilities and proposing improvements by incorporating the Weiszfeld algorithm. Furthermore, the relevance of different distance measures,

such as the Euclidean, Manhattan and Dijkstra algorithms, is examined in the context of the journey to crime. Next, the thesis evaluates the consistency of the directionality of the SHO series using circular statistics, and finally, an alternative to the effect of classifying marauding and travelling offenders is proposed, overcoming the limitations of current software by means of machine learning techniques.

In summary, this PhD thesis presents a number of concepts and approaches that can significantly contribute to the research progress in the field of geographical profiling. However, challenges and open questions remain. These issues will undoubtedly demand the attention and detailed analysis of future researchers.

INTRODUCCIÓN

La exposición del fenómeno del asesinato en serie al ámbito público, principalmente a través de la literatura y el cine, ha generado una fascinación cultural que ha oscurecido la gravedad y la realidad de estos delitos.

En este contexto, es esencial reevaluar y repensar la forma en que abordamos el estudio del asesinato en serie. Esto implica adoptar enfoques de investigación más rigurosos y objetivos, que se alejan del sensacionalismo y buscan respuestas fundamentadas en la evidencia y el análisis crítico. A pesar de los desafíos presentes, es imperativo continuar con la investigación en este campo, adaptando definiciones y enfoques de manera efectiva para abordar y superar estos obstáculos.

En este sentido, la contribución conjunta de investigadores como Rossmo, Canter, Levine, Godwin y O'Leary, entre muchos otros, ha sido crucial en la formulación e implementación de algoritmos matemáticos para el perfilado geográfico. Esta metodología, que se enfoca en el análisis de patrones espaciales asociado a una serie de delitos, tiene como objetivo principal determinar la zona más probable donde reside el delincuente (Rossmo, 2000). El extenso cuerpo de trabajo establecido por estos investigadores continúa expandiendo e inspirando a otros a desarrollar nuevas técnicas y estrategias que, en última instancia, mejorarán su aplicación.

Sin embargo, su implementación sigue estando condicionada por una serie de hipótesis demasiado simplificadas, difíciles de evaluar durante una investigación o incluso no verificadas a nivel individual de observación. El error de la elaboración de perfiles geográficos puede deberse en parte al hecho de que los algoritmos de perfilado geográfico tienden a descuidar lo que sabemos

sobre las elecciones de objetivos y el comportamiento delictivo de los delincuentes (Stangeland, 2005) y solo se centran en las ubicaciones del delito sin tener en cuenta el contexto geográfico, temporal y cognitivo. Todas las herramientas del perfilado geográfico asumen que las estructuras de oportunidades no varían en el espacio (Bernasco, 2007). Tal vez sea inapropiado seleccionar una teoría (*distance decay*) como única respuesta y sugerir que es superior en comparación con las alternativas.

En contraposición a la postura de Rossmo, quien sugiere que la introducción de nuevas herramientas, incluso una que pudiera modificarse para experimentar con nuevas ideas, no aportaría nada nuevo al campo investigativo (*P. MacLaren, personal communication, April 8, 2008*), aún subsisten retos y cuestiones sin resolver en el ámbito del perfilado geográfico, que sin duda demandaran un análisis detenido por parte de los investigadores en el futuro (English, 2008a).

La revolución en inteligencia computacional y la disponibilidad de grandes conjuntos de datos han impulsado la investigación en homicidios en serie hacia una era de modelos predictivos más atractivos y una comprensión más profunda. Los investigadores, ahora más que nunca, están en proceso de diseño de modelos que no solo ayudan a identificar a posibles futuros autores de homicidios en serie, sino también a decodificar patrones delictivos, lo que se traduce en una herramienta esencial para anticipar comportamientos delictivos. Esta evolución en la metodología se refleja en estudios recientes como los de (Beauregard y Martineau, 2016; Ioana, 2013; Miller, 2014), que han abordado estos enfoques innovadores en el ámbito criminológico.

Wang (2012) subraya la necesidad de buscar colaboraciones interdisciplinarias para inyectar nuevas perspectivas, nuevos métodos y conocimientos en el análisis y la actuación policial con orientación espacial, donde se requiere un equipo interdisciplinario de criminólogos, informáticos, geógrafos y tal vez físicos.

Por último, la sinergia entre el mundo académico y las fuerzas y cuerpos de seguridad pública es esencial para avanzar en el desarrollo de los SIG policiales y para aprovechar plenamente sus beneficios. Esto implica la necesidad de establecer una confianza mutua, promover una comunicación efectiva y fomentar una estrecha colaboración entre ambas partes.

Basándonos en los resultados de investigaciones previas, el objetivo de la presente tesis doctoral es analizar la metodología de la elaboración de perfiles geográficos, identificar dónde se pueden encontrar problemas y hacer sugerencias sobre cómo se puede mejorar la elaboración de perfiles geográficos. Específicamente, nos concentramos en aquellos aspectos que serían de mayor relevancia y accesibilidad en una investigación. Adicionalmente, buscamos desarrollar una herramienta de perfilado que integre los puntos fuertes identificados, y que aborde y rectifique las limitaciones y amenazas detectadas en los softwares actuales.

Estructura de la tesis

La presente tesis doctoral está estructurada en tres partes y un total de dieciséis capítulos.

La parte primera, se organiza en torno al perfil geográfico;

[Capítulo 1. Antecedentes teóricos] En este capítulo se revisa las perspectivas teóricas relevantes que pueden vincularse a la elaboración de perfiles geográficos.

[Capítulo 2. Perfil geográfico] Concepto, condiciones y limitaciones del perfilado y las dimensiones en las que se desarrollaran los objetivos de la segunda parte de la investigación.

[Capítulo 3. Sistemas de Información Geográfica] dedicado a los Sistemas de Información Geográfica (SIG), realizando una revisión de las herramientas de perfilado geográfico existentes en la actualidad, con el propósito de analizar sus debilidades y fortalezas.

[Capítulo 4. Estrategias de perfil geográfico] En el capítulo cuatro, nos centramos en las estrategias del perfilado geográfico. Exploramos las estrategias de distribución espacial, probabilidad y de dispersión.

En la parte segunda de la investigación, se propone primero identificar las restricciones y factores que permiten el cálculo de un perfil geográfico efectivo, con la especificidad de enfocarse solo en las variables que podrían estar disponible durante una investigación.

[Capítulo 5. Estudio empírico] nos centramos en explicar los principales objetivos e hipótesis de la investigación.

[Capítulo 6. Método] dedicado al marco metodológico del estudio sobre delincuentes homicidas en serie (SHOs), en el cual se desarrollan: una revisión de datos históricos de SHOs, las limitaciones del proceso de recopilación de datos, las diferentes técnicas empleadas (revisión sistemática de una recogida de datos preliminar y la elaboración de la ficha con la que se ha

trabajado); la selección de variables; estudios instrumentales utilizados, ámbito geográfico en el que se ha desarrollado y el período cronológico de la misma.

[Capítulo 7. Optimización perfilado geográfico] se exponen los procesos realizados en un sistema de información geográfico en un entorno de QGIS para la realización de la herramienta (GEO-SCRIPT) en la que se basan los cálculos de variables necesarias para realizar la tesis doctoral.

En la parte tercera se exponen los estudios empíricos que componen la presente tesis doctoral.

[Capítulo 8. Humanos versus Algoritmos] Se presenta el primer estudio centrado en los resultados obtenidos en dos universidades en relación con el dilema de que los humanos podrían ofrecer resultados tan buenos como el software de perfiles geográficos.

[Capítulo 9. Evaluación de estrategias de dispersión] Se presenta el segundo estudio, donde se analizan dos escuelas de interpretación del perfil geográfico, un enfoque que utiliza la teoría de la distribución espacial y el otro que trabaja con distancias de probabilidad, en la tesis elaboraremos y analizaremos un nuevo enfoque de perfilado denominado estrategia de distribución de dispersión.

[Capítulo 10. La aplicación del perfil geográfico de Newton y Swoope] Se presenta el tercer estudio, en el que se realiza una evaluación del modelo propuesto por Newton y Swoope en 1980.

[Capítulo 11. Modificación del algoritmo de perfilado geográfico Newton y Swoope] Se presenta el cuarto estudio, incorporando el algoritmo Weiszfeld aplicado en el modelo de perfilado geográfico de Newton-Swoope, que ha introducido medidas robustas para centrar datos en presencia de valores atípicos.

[Capítulo 12. Merodeadores y Viajeros] se presenta el quinto estudio de la tesis doctoral, que se enfoca en examinar modelos de aprendizaje automático para clasificar a un SHO desconocido como viajero o merodeador.

[Capítulo 13. Funciones decaimiento de la distancia] En el sexto estudio, concebiremos que la comprensión actual del viaje hacia el crimen es incompleta. Al estudiar los patrones de los delincuentes, queda claro que la movilidad y el decaimiento de las distancias de los delincuentes no están entrelazados a nivel individual en la misma medida que a nivel global.

[Capítulo 14. El perfil geográfico comportamiento y adaptación al medio] En el séptimo estudio, entenderemos que el desarrollo de una estrategia de probabilidad que responda a las características locales (superficie isotrópica) podría aumentar significativamente la precisión de las predicciones de perfiles geográficos.

[Capítulo 15. Explorando la consistencia direccional] Finalmente, en el último estudio nos detendremos en el componente direccional, un área poco investigada en la geografía del delito, y en el que se analizara el comportamiento de la variable angular mediante la estadística circular (Rayleigh test, Moore test).

[Capítulo 16. Discusión y conclusiones] se presenta una discusión global y conjunta de todos los estudios derivados de la presente tesis doctoral, así como los hallazgos encontrados, las principales conclusiones, y las perspectivas de futuros estudios.

PARTE I PERFIL GEOGRÁFICO

Capítulo 1

ANTECEDENTES TEÓRICOS

En este capítulo, se presenta el marco teórico fundamental necesario para entender los avances propuestos en esta tesis doctoral. Seguidamente, se exploran las teorías pertinentes que se interrelacionan con el concepto del perfilado geográfico.

El perfilado geográfico se origina en diversas teorías sociológicas sobre el delito, con un enfoque especial en la criminología ambiental. Remontándonos a la década de 1920, la escuela de Chicago innovó al idear múltiples métodos destinados a examinar la distribución delictiva. El objetivo de tales técnicas era descifrar las diferencias geográficas en la incidencia delictiva basándose en la organización intrínseca de las áreas urbanas y en los fenómenos ambientales y urbanísticos asociados.

Gran parte de las bases teóricas para la creación de perfiles geográficos tienen su base científica en la criminología ambiental, y más específicamente; en el principio de menor esfuerzo (Cornish y Clarke, 1986), teoría de la actividad cotidiana (Cohen y Felson, 1979), elección racional (Cornish y Clarke, 1986), la teoría del patrón delictivo (Brantingham y Brantingham, 1995; Brantingham y Brantingham, 1981), decaimiento de la distancia (Capone y Nichols, 1976), rango ambiental (Canter y Larkin, 1993) y el efecto de zona de amortiguación (Brantingham y Brantingham, 1981).

Si bien, Levine (2005) indica que el perfilado geográfico no se fundamenta firmemente en teorías probadas empíricamente, pero sí que utiliza varios enfoques teóricos del marco más amplio de la criminología ambiental: la teoría del patrón delictivo (Brantingham y Brantingham, 1984),

el enfoque de actividades cotidianas (Cohen y Felson, 1979) y la perspectiva de la elección racional (Cornish y Clarke, 1986).

Los investigadores han adoptado, parcialmente, estas tres teorías para desarrollar modelos matemáticos informatizados que estiman la ubicación del domicilio de un delincuente. No obstante, hasta ahora, escasos estudios han puesto a prueba teorías o han ofrecido evidencia empírica que combine la actividad cotidiana de los delincuentes o las características geográficas de las áreas que rodean los lugares del delito (Goodwill et al., 2014).

1.1 Teoría del patrón delictivo

Los patrones delictivos locales nos muestran acerca de cómo interactúan las personas con su entorno físico y generan oportunidades delictivas. La teoría del patrón delictivo, un componente esencial de la criminología ambiental, analiza cómo se mueven en el tiempo y espacio los sujetos y las cosas implicadas en un delito (Felson y Clarke, 1998).

Brantingham y Brantingham (1984), consideran cómo los delincuentes se mueven y desplazan en el tiempo y el espacio, planteando que el delito tiene un base racional ya que los delincuentes se mueven predominantemente dentro de espacios familiares en los que se identifican objetivos potenciales. Por lo tanto, el espacio de actividad de cada persona está limitado por su espacio de conciencia, que se refleja en el propio "mapa mental" de cada individuo. Un mapa mental es una representación del entorno espacial almacenado en la mente de las personas (Kitchin, 1994). Este mapa mental no es una representación exacta de la realidad, sino que refleja el grado en que estamos familiarizados con ciertos lugares. Por lo tanto, un mapa mental también es dinámico y se adapta a medida que cambian nuestras actividades cotidianas.

Debido a que el mapa mental cubre principalmente el espacio formado por las actividades cotidianas más recientes, se utiliza el término espacio de conciencia (Brantingham y Brantingham, 1984). Los espacios de conciencia son, los lugares de los que una persona es consciente y el término relacionado “espacio de actividad” se refiere al subconjunto de ubicaciones que las personas experimentan directamente durante sus actividades. En su teoría, Brantingham y Brantingham (1984), describen cómo diferentes puntos de anclaje, como el domicilio, el trabajo y las áreas de compras, influyen en el conocimiento espacial de un delincuente. Estos lugares y las rutas entre ellos son parte del mapa mental que las personas tienen de su entorno (véase figura 1-1). El concepto de espacio de conciencia no se limita únicamente al área física de actividad, sino que va más allá de lo que normalmente se encuentra en el rango visual. Además se extiende hacia otras fuentes de información, como el boca a boca, las noticias o los medios de comunicación (Brown y Moore, 1970). Al decidir la ubicación para una futura actividad, uno podría optar por regresar a un sitio dentro de su espacio de actividad familiar, explorar un nuevo sitio que ya está en su espacio de conciencia debido a fuentes secundarias, o aventurarse en un lugar del cual carece de conocimiento previo. No obstante, la distribución no uniforme de objetivos lleva a que los delincuentes se inclinen por un subconjunto específico de su espacio de conciencia, al que se le conoce como espacio de oportunidad. Es probable que tanto el espacio de actividad como el espacio de oportunidad se solapen en su totalidad (Brantingham y Brantingham, 1984).

La teoría geométrica del delito analiza el comportamiento espacial de un delincuente motivado, quien realiza sus actividades cotidianas entre puntos clave de actividad y las rutas que conectan. Los nodos son lugares donde las personas realizan de forma regular sus actividades cotidianas, tales como el domicilio, la escuela, zonas de ocio y compras, residencia de familiares

o amigos o el lugar de trabajo, entre otros. Mientras que las rutas son los trayectos o vías que las personas utilizan para desplazarse entre los nodos.



Figura 1-1: Teoría del patrón delictivo según Brantingham y Brantingham (1984). Adaptado de van de Kemp (2014, p.21).

Es necesario ampliar este espacio de conocimiento para incluir el espacio indirecto (Brown y Moore, 1970). En las últimas tres décadas, la transformación de los canales de comunicación ha llevado a una expansión del espacio de conocimiento hacia las redes sociales, lo que ha generado nuevas oportunidades para selección de objetivos.

La elección de un objetivo específico por parte de un delincuente o la definición de su área de caza puede estar tan influenciada por el espacio de contacto indirecto como lo está por su espacio de actividad. De hecho, el alcance de lo que es visible ha experimentado una transformación significativa debido a las nuevas tecnologías. En las redes sociales, se ha vuelto común que los usuarios compartan información detallada sobre sus actividades diarias, la de sus

amigos, sus domicilios y otros aspectos personales. Además, plataformas como *Google Earth* y *Google Maps* proporcionan información precisa sobre la accesibilidad y las posibles rutas de desplazamiento, ampliando así nuestra comprensión y visualización del espacio.

La premisa fundamental en cualquier metodología de perfilado geográfico es que las características de la ubicación del delito están estrechamente vinculadas al comportamiento espacial del delincuente. En este contexto, se busca explorar tres conceptos geográficos fundamentales: el atractivo del lugar, la densidad y la proximidad. Estos conceptos son clave para comprender cómo influyen los factores geográficos en la ocurrencia y distribución de los delitos.

Ciertos lugares ofrecen mayores oportunidades delictivas que otros en tanto coincidan con el espacio de conciencia del delincuente, Brantingham y Brantingham (1995) apuntaron a que lo mismo, guarda relación con la existencia de tres tipos de ambientes: los generadores, los atractores y áreas neutrales. Los ambientes generadores son aquellos que atraen a muchas personas por razones no delictivas, dándose esta motivación en todo caso sólo en ciertos momentos y de forma aislada. Cuando se presentan oportunidades al delito a ciudadanos que originalmente demostraban unos valores cívicos, la tentación puede llevarlas a actuar de manera contraria a sus principios. Los ambientes atractores son aquellos que atraen a personas que ya tienen una motivación delictiva expresa y que acuden allí porque tienen constancia de que en el lugar hay oportunidades para la comisión de ciertos tipos de delitos. Al reunir oportunidades que son muy concretas, lo más habitual es que estos delincuentes motivados acudan desde zonas ajenas a este ambiente, no siendo por tanto originarios de allí. Los que sí son naturales de la zona muy probablemente residan en esta área después de desplazarse de otras zonas que no le ofrecían las mismas oportunidades o que no eran tan próximas a ellas.

Las áreas neutrales al crimen son lugares que no crean oportunidades particulares de ofensa y no atraen particularmente a las personas.

Por lo tanto, no se puede afirmar categóricamente que las oportunidades delictivas existan inherentemente en un entorno, dicho ambiente no actuaría necesariamente como un generador o atractor de delitos. Sin embargo, raramente se encuentran entornos que cumplan con estas características de manera pura. Es más común encontrar áreas mixtas, cuyas características varían según el tipo de delito predominante.

Es importante destacar que es precisamente este enfoque el que constituye la base conceptual y teórica principal del aspecto central de este trabajo. Resulta que los hallazgos empíricos acerca de la relación entre la ubicación geográfica del domicilio del delincuente y los lugares donde comete sus delitos proporcionan una base de evidencia esencial para el desarrollo de algoritmos en el perfilado geográfico.

1.2. Teoría de la actividad cotidiana.

El enfoque de actividades cotidiana postula que el delincuente y las víctimas (u objetivos) generalmente se encuentran durante actividades o rutinas diarias, no delictivas (Cohen y Felson, 1979).

En este modelo, la "oportunidad" es un concepto importante para explicar el comportamiento delictivo. Los delitos ocurren como resultado de la convergencia en el espacio y el tiempo de tres elementos importantes: un delincuente motivado, un objetivo adecuado y vulnerable y la ausencia de un guardián capaz (Cohen y Felson, 1979). Por esta razón, al hilo de

este planteamiento, el acto delictivo no tiene la categoría de acontecimiento desviado de la actuación normal (Dern et al., 2004).

La teoría de la actividad cotidiana a menudo se reduce a la relación: delincuente-objetivo-guardianes. Sin embargo, la teoría incorporó inicialmente una perspectiva sobre el papel de la tecnología y la organización social en la evolución de la criminalidad (Trotta, 2014).

En los modelos actuales de elaboración de perfiles geográficos, estos procesos de decisión apenas tienen lugar. Como consecuencia, muchos factores relevantes que influyen en el comportamiento espacial de los delincuentes no se utilizan para ayudar a la elaboración de perfiles (van Der Kemp y van Koppen, 2007).

1.3. Teoría de elección racional

La teoría de la elección racional (*rational choice theory*) se ha utilizado durante mucho tiempo para modelar comportamientos sociales y económicos. Este teórico marco explica el proceso individual de toma de decisiones a través de la maximización de la utilidad. La teoría debe verse como una simplificación de la realidad o heurística (Cornish y Clarke, 1986) para algunos propósitos de modelado.

Estudios anteriores han aplicado la teoría económica a la criminología utilizando la teoría de la utilidad esperada (Von Neumann y Morgenstern, 1944) y la teoría de la perspectiva (Kahneman y Tversky, 1979) para modelar a un criminal que valora los beneficios para sí mismo de cometer un delito frente a las probabilidades de ser detenido y el daño asociado.

En Criminología, la teoría de la elección racional (Cornish y Clarke, 1986) es útil para comprender la lógica, a veces implícita, en la selección de sitios para delincuentes (Lundrigan y Canter, 2001). De hecho, la decisión del delincuente de cometer un delito y seleccionar una víctima

específica y su ubicación se rige por su esfuerzo asociado, riesgo, coste y recompensa (se destaca el cálculo del coste-beneficio del individuo que pondera la ganancia delictiva pretendida y la probabilidad de ser descubierto). Sin embargo, la racionalidad individual está limitada por tres elementos: la información disponible, las limitaciones cognitivas de la mente y el tiempo disponible para tomar la decisión (Simon, 1992).

Además, cuando el delincuente gana experiencia para un comportamiento específico, puede adoptar algún proceso de comportamiento automático en lugar de pasando por un ejercicio típico de toma de decisiones racional (Wortley y Tilley, 2014). A este respecto, el proceso de decisión puede caracterizarse por reglas simples de detención que no implican cálculos de optimización (Gigerenzer y Goldstein, 1996).

Así pues, la elección racional en lugar de ver el delito como el resultado de motivaciones delictivas, tiene en cuenta los deseos, las preferencias y motivaciones del potencial infractor como procesos psicológicos que son similares a los de cualquier persona no infractora y que se encuentran en continua interacción con las oportunidades y limitaciones que, en su caso, faciliten o inhiban la conducta delictiva (Cornish y Clarke, 1986).

De acuerdo con la teoría de la elección racional, las personas son consideradas seres racionales mediante la realización de diferentes comportamientos como resultado de un complejo proceso de toma de decisiones influenciado por factores internos (personalidad, intereses, experiencia, etc.) y factores externos (condiciones de vida, nivel de esfuerzo, nivel de seguridad, severidad del castigo, etc.). En consecuencia, cada persona percibe específicamente las oportunidades delictivas con respecto a su contexto (Cornish, y Clarke, 2016). Cornish y Clarke (1986) advierten, que no sólo los delitos contra la propiedad, sino también muchos delitos de

violencia, incluyendo homicidio y violación, presentan un sustancial contenido de racionalidad demostrando que la decisión se toma sopesando los factores.

De este modo, esta perspectiva plantea la imagen de un delincuente que piensa antes de actuar, aunque lo haga solo por un momento, centrándose en el estudio del proceso de la toma de decisiones inmediatamente previo a la comisión del delito. De tal forma que la decisión será constante entre los delincuentes, es decir, que todo infractor realizará un balance mínimo, si bien este cambia a través de los delitos y será diferente dependiendo de cada circunstancia o situación concreta (Clarke, 2012).

Una crítica significativa a este enfoque teórico es que centra los procesos cognitivos como el núcleo principal detrás del acto delictivo. Así, delitos como las agresiones sexuales o los homicidios, que se caracterizan por su espontaneidad e impulsividad y que no buscan un beneficio posterior, quedan sin respaldo explicativo en esta teoría. La psicología ambiental aborda los posibles procesos racionales detrás de estos delitos tan perturbadores y cargados de emoción. Aunque los homicidios perpetrados por asesinos en serie no pueden ser categorizados como actos racionales, y más bien se presentan como fruto de intensas emociones y falta de control sobre los impulsos, las teorías de la psicología ambiental sugieren que la elección del lugar donde se desecha el cuerpo podría estar influenciada por una racionalidad discernible.

Meaney (2004) explica la diferencia en la distribución de ladrones, pirómanos y agresores sexuales asumiendo que los pirómanos y los agresores sexuales son más impulsivos que los ladrones cuando cometen su delito. Se asume que los pirómanos y los delincuentes sexuales son delincuentes más motivados emocionalmente y que son menos racionales.

Independientemente del proceso de decisión subyacente, Cohen y Felson (1979) proponen que la perspectiva de elección racional explica mejor el contenido de las decisiones. Mientras que

el enfoque de actividades cotidianas explica mejor por qué se toman las decisiones, según (Goodwill et al., 2014).

1.4. La hipótesis del círculo

Canter y Larkin (1993) desarrollaron una teoría basada en el estudio de violadores en serie en Londres. La hipótesis del círculo describe cómo los delincuentes residen más a menudo dentro de un área circunscrita por sus delitos, definida por un círculo con un diámetro igual a la distancia entre los dos lugares más externos de los delitos (Youngs, 2008). Dentro de esta hipótesis del círculo surgieron dos tipos de delincuentes, los merodeadores y los viajeros (véase capítulo 12). Ambos tipos de delincuentes atacan desde su lugar de origen y regresan a ese lugar después de completar el delito. El merodeador delinque relativamente cerca de su lugar de residencia, situando este lugar dentro del círculo definido por los dos lugares más externos de la infracción. El viajero abandona la ubicación general del hogar para delinquir en una zona geográfica diferente.

1.5. Decaimiento de la distancia

El postulado de la disminución de la frecuencia de los hechos delictivos en proporción directa al incremento de la distancia respecto al domicilio del agresor está estrechamente ligado al principio superior de cercanía y/o a la ley del menor esfuerzo. Este axioma indica que, bajo la condición de una igual distribución de las posibilidades potenciales (en las que desempeñan un papel determinados parámetros como la atracción del objetivo, el uso de recursos y medios o la necesidad de seguridad), el agresor elegirá las variantes que, desde su punto de vista, le exijan una mínima modificación ambiental.

Esta expresión encuentra sus raíces en la familia de modelos gravitacionales basada en la ley fundamental de atracción de Isaac Newton (Kent et al., 2006). De acuerdo con estos autores, el término decaimiento con la distancia se utilizó originalmente para describir el hecho de que la atracción entre dos cuerpos disminuye a medida que aumenta la distancia entre ellos. El hallazgo recurrente de que la mayoría de los viajes delictivos son cortos frecuentemente se conoce como una función de decaimiento con la distancia. La frecuencia de los viajes delictivos tiende a disminuir a medida que aumenta la distancia desde el punto de origen del delincuente. Esta relación inversa entre la distancia y la frecuencia de viaje se argumenta como evidencia de la preferencia racional de los analistas (Cornish y Clarke, 1986) para minimizar el esfuerzo percibido y el tiempo requerido para localizar objetivos de crimen adecuados.

1.6. Zona de seguridad

Turner (1969) fue el primero en proponer la existencia de una “zona de seguridad” alrededor de la base de origen del delincuente, donde es menos probable que se realice actividad delictiva, debido a la posibilidad de ser reconocido. Esta idea también puede estar relacionada con la falta de oportunidades delictivas cerca de sus hogares (O’Leary, 2011b; Rengert et al., 1999; Rossmo, 2000). Esta área para el delincuente representa un equilibrio optimizado entre la maximizar las oportunidades y la minimizar los riesgos asociados (Canter y Gregory, 1994).

Este concepto fue desarrollado por (Brantingham y Brantingham, 1981), autores de la teoría que aporta la base teórica principal al perfil geográfico. La zona de seguridad, o *buffer zone*, se refiere a un área centrada alrededor del punto de anclaje (domicilio o lugar de trabajo). Dentro de esta zona, los objetivos son considerados menos deseables debido al riesgo percibido de cometer delitos demasiado cerca de su punto de anclaje.

1.7. Teoría de la acción situacional

La teoría de la acción situacional (en adelante SAT) es una teoría general, dinámica y basada en mecanismos del delito y sus causas que analiza el delito como acciones morales. Busca explicar algunos de los problemas de la teoría criminológica, es decir, los mecanismos causales y el papel de los aspectos individuales y ambientales en la causalidad del delito (Wikström y Treiber, 2007). La teoría define el crimen como una ruptura de las reglas morales, es decir, la noción de que las acciones pueden ser correctas o incorrectas.

La teoría de la acción situacional emergió a finales de la década de 1990 y principios de 2000. Aunque su primer esbozo fue publicado en 2004, ha experimentado refinamientos y expansiones en los últimos 15 años (Wikström et al., 2018). A pesar de no gozar de la misma popularidad que otras teorías previamente discutidas, ha ganado reconocimiento, especialmente entre los criminólogos europeos.

Esta teoría sostiene que las acciones humanas emergen de cómo un individuo percibe sus opciones de comportamiento y toma decisiones al respecto (Wikström y Treiber, 2007). Según Wikström y Treiber (2007) para que se dé un acto delictivo, factores situacionales, tales como el ambiente (entendido tanto en términos físicos como sociales) y las características personales y experiencias previas, influyen en las decisiones humanas. Esta influencia se conceptualiza como una "configuración".

La teoría de la acción situacional fue formulada con el propósito de superar la fragmentación y la integración insuficiente comúnmente observadas en los conocimientos criminológicos. Su objetivo es proporcionar un marco teórico holístico para entender el crimen y sus causas (Wikström et al., 2018).

La teoría pone especial énfasis en la moralidad del delincuente. Dado que cada individuo posee juicios y hábitos morales únicos, estos determinan su comportamiento de maneras diversas. La perpetración de un delito podría ser un reflejo de fallos en estas creencias y hábitos morales, lo que sugiere que lo que un delincuente considera "correcto" o "incorrecto" puede no alinearse con la percepción moral de otro individuo.

El SAT propone que la motivación de una persona para actuar conforme a sus posibles acciones genera oportunidades, y estas, a su vez, desencadenan tentaciones (Wikström y Treiber, 2007). La tentación, al ser una potente fuerza motivacional, suele conducir a la transgresión de normas morales, es decir, a la comisión de delitos. La aplicación del SAT es significativamente relevante al tratar la metodología de elaboración de perfiles geográficos. Dicha teoría se fundamenta en el concepto de elección racional, centrandó su análisis en comprender el "mapa mental" del delincuente (Rossmo, 2000). De acuerdo con Rossmo (2013; 2000), las oportunidades y tentaciones propias de ciertos entornos desempeñan un papel esencial en la decisión del delincuente respecto a dónde perpetrar un crimen. Por consiguiente, es plausible que el delincuente evalúe racionalmente los beneficios y riesgos involucrados.

Así, el enfoque de elección del SAT se manifiesta como un recurso invaluable para la construcción de perfiles geográficos, puesto que integra los factores previamente mencionados y el concepto de autocontrol (Öhrn, 2016).

Capítulo 2

PERFIL GEOGRÁFICO

En este capítulo, se delinearé el marco teórico fundamental para la comprensión de la tesis doctoral. A lo largo del mismo, se explorará en profundidad la metodología de perfiles geográficos, se señalarán los posibles desafíos o problemas asociados y se ofrecerán recomendaciones para perfeccionar y optimizar la elaboración de perfiles geográficos.

1. Concepto

El análisis de patrones espaciales en la delincuencia posee una rica tradición histórica. Los albores de esta investigación se remontan a los estudios pioneros de Guerry¹ en Francia, a comienzos del siglo XIX. Posteriormente, Tobias (1972) profundizó en la materia, estudiando las particularidades de la distribución de delincuentes sexuales en ciudades como Londres y Manchester.

Brantingham y Brantingham (1981), afirmaron que, para descifrar estos patrones espaciales relacionados con los delincuentes, es esencial recurrir a herramientas investigativas como el perfilado geográfico. Esta metodología facilita la conexión entre el lugar del delito y el

¹ André-Michel Guerry abogado francés y estadístico. Junto con Adolphe Quetelet, puede ser considerado como el fundador de las estadísticas morales que condujeron al desarrollo de la criminología, la sociología y, en última instancia, las ciencias sociales modernas.

domicilio o área de residencia del delincuente, ofreciendo así a los cuerpos de seguridad una herramienta valiosa para identificar al autor del hecho delictivo.

En las últimas décadas, los avances en criminología han conducido a técnicas de investigación y análisis más avanzados, que han mostrado distintos niveles de éxito. Dentro de estas técnicas, destaca el análisis geográfico. Acuñado por el Dr. Milton Newton a mediados de la década de 1980 como análisis "geoforenses", este concepto busca identificar y describir el comportamiento espacial del delincuente en relación con el lugar del crimen (Newton y Swoope, 1987). Hoy, esta área de investigación se conoce comúnmente como perfil geográfico. Esta herramienta de apoyo a la toma de decisiones integra diversas metodologías de investigación y análisis, tanto cuantitativas como cualitativas. En ella, los criminólogos calculan la situación geográfica probable de una residencia de un delincuente en serie basada en la distribución de sitios delictivos vinculados (Canter y Gregory, 1994; Godwin, 2001; Rossmo, 2000).

La elaboración de perfiles geográficos tiene un componente tanto objetivo como subjetivo, como lo describen Newton y Newton (1985). El componente subjetivo gira en torno a la interpretación y reconstrucción del "mapa mental" del delincuente. El componente objetivo utiliza técnicas geográficas para analizar e interpretar patrones distintivos de delitos.

Durante la década de 1970, la Unidad de Ciencias del Comportamiento de la Oficina Federal de Investigación (en adelante FBI) comenzó a formar perfiladores de investigación, con el objetivo de crear perfiles criminales que contribuyeran a la detención de delincuentes. A través de entrevistas a criminales y el análisis de informes de casos, surgió el concepto de "asesino en serie" (Reid, 2017).

En la década de 1990, aparece una innovadora herramienta para las organizaciones policiales: el uso de mapeo en relación con delitos en serie. Buscando entender los patrones

espaciales de los delincuentes, se emplearon técnicas como el perfil geográfico. Esta estrategia permitió establecer conexiones entre el lugar del delito y la base de operaciones del delincuente, facilitando así la labor de identificación por parte de la policía (Edwards, 2004).

Rossmo (1997), señaló que la fusión de perfiles psicológicos y geográficos contribuye de manera efectiva a proporcionar a los investigadores una visión integral del individuo responsable de los delitos en estudio. El perfil psicológico proporciona información sobre la posible motivación de un delincuente, comportamiento y estilo de vida; por lo tanto, está directamente relacionado con su actividad espacial. Mientras tanto, el perfilado geográfico tiene un enfoque orientado en el comportamiento espacial del delincuente dentro del contexto de las ubicaciones y las relaciones espaciales entre los diversos lugares delictivos.

La elaboración de un perfil geográfico es un proceso complejo que va más allá de la mera inserción de ubicaciones en un software para obtener un mapa basado en estos puntos de datos. El perfil geográfico añade una capa adicional de información, potenciando la comprensión del comportamiento del delincuente y mejorando la precisión en la identificación y localización de este.

La literatura presenta múltiples definiciones en torno al concepto de perfiles geográficos. A continuación, analizaremos algunas de estas interpretaciones:

"Una metodología de investigación que analiza la ubicación de una serie enlazada de crímenes para determinar el área más probable de residencia del delincuente" (Rossmo, 2000, p.1).

“El perfil geográfico es una metodología de investigación que analiza la secuencia espacial de las ubicaciones de actos delictivos (patrón espacial) para determinar el área más probable donde el delincuente vive o reside y trabaja, así como su itinerario” (Ksenija y Jelena, 2017, p5).

A nivel académico y contemporáneo, los perfiles geográficos se delimitan como:

"Una estrategia de gestión de la información para las investigaciones delictivas que analiza la información del sitio delictivo para determinar el área más probable de residencia del delincuente" (Rossmo, 2000, p.259).

"El perfil geográfico se define como aquella técnica de análisis de la actividad espacial o geográfica de los delincuentes aplicada a la investigación criminal" (Garrido y López, 2014, p.53).

"La elaboración de perfiles geográficos es el proceso mediante el cual se puede determinar la información geográfica sobre un evento o un individuo. El perfil geográfico del delincuente establece la base de operaciones del delincuente. El perfil geográfico de la serie de delitos establece las áreas donde es probable que ocurran los delitos y, por lo tanto, proporciona una predicción de la ubicación del próximo delito" (Leone et al., 2010, p.5).

"Un método para estimar la región geográfica de la ubicación del hogar, el lugar de trabajo u otros puntos de anclaje relevantes de un delincuente basado en suposiciones y datos nomotéticos" (Turvey, 2016, p.656).

"La elaboración de perfiles geográficos del delincuente es un método de investigación penal que utiliza un análisis del patrón espacial de las escenas del crimen para determinar un área de búsqueda en la que se puede encontrar el lugar de residencia del delincuente" (Koppen y Kemp, 2010, p.230).

Al igual que con la elaboración de perfiles criminales, no pretende ser una panacea de investigación, pero más bien, una herramienta que ayuda a la policía y prioriza las áreas de búsqueda (Ratcliffe, 2006; Rossmo, 1997a). Idealmente, un perfil geográfico debería no solo seguir, sino también complementar y enriquecer un perfil criminal ya completo, una vez que este haya sido confeccionado.

Se identifica el perfil geográfico como un sistema de apoyo a las decisiones utilizado para hacer estimaciones de la probable región geográfica de la ubicación del hogar de un delincuente (Rossmo, 2000), aunque también puede identificar dónde trabaja el delincuente (Ratcliffe, 2006) o algún otro lugar con el que el delincuente esté familiarizado (denominados nodos de actividad).

En resumen, este capítulo reconoce la importancia de seguir adelante con investigaciones empíricas y adaptar definiciones y enfoques para abordar mejor estos desafíos.

Es gracias a este planteamiento por lo que se nos ha abierto la posibilidad de redefinir el término perfil geográfico. El objetivo es evitar una simplificación excesiva de la riqueza teórica necesaria para construir modelos explicativos. Por lo tanto, en esta tesis doctoral, se propone una aproximación al concepto del perfil geográfico, aproximación que resulta más estable conforme a las demandas de los modelos teóricos en los que se aplica.

El perfil geográfico es una metodología enfocada en la actividad espacial, temporal y cognitiva. Su propósito está orientada al estudio de la toma de decisiones de los delincuentes seriales, con el objetivo principal de determinar la zona más probable de residencia del delincuente y estimar áreas de acción para sus futuros objetivos.

2. Condiciones y limitaciones

La creación de perfiles geográficos tiene ciertas condiciones y limitaciones en su aplicación. Por esta razón este método se encuentra con las opiniones de los críticos que señalan sus deficiencias adicionales escrupulosidad y marco en su aplicación. Estas imperfecciones y limitaciones de aplicación del perfil geográfico fue compilado por Turvey (2016).

Además, la elaboración de perfiles geográficos en entornos operativos difiere de cómo se utiliza en la elaboración de perfiles geográficos académicos (Daniell, 2008). A lo largo de los años,

los académicos se han centrado en cuestiones como la complejidad y precisión de la elaboración de perfiles geográficos, las estructuras de oportunidades, los patrones de merodeadores o viajeros y las aplicaciones teóricas de la metodología (Bernasco, 2010; Block y Bernasco, 2009; Kocsis et al., 2002; Paulsen, 2006; Snook et al., 2004; Snook, Zito, et al., 2005). Aunque los resultados de la elaboración de perfiles geográficos académicos han proporcionado material interesante, el enfoque de los estudios ha sido criticado por ser demasiado académico, es decir, los estudios guardan una semejanza limitada con el uso de la elaboración de perfiles geográficos en entornos operativos (Daniell, 2008).

La elaboración de perfiles geográficos operativos ha demostrado potencial, sin embargo, su eficacia en apoyo a las investigaciones policiales aún no ha sido validada en una proporción significativa de casos (Canter, 2005). Se sugiere que las limitaciones en la eficacia de la elaboración de perfiles geográficos pueden atribuirse a múltiples fuentes de error y a la interferencia en los datos proporcionados por la policía. Sin embargo, una porción del problema relativo a la elaboración de perfiles geográficos podría estar enraizada en el hecho de que los perfiladores, en muchas ocasiones, omiten información esencial acerca de la selección de objetivos y el comportamiento delictivo de los infractores. Esta omisión podría resultar en una representación incompleta y, por lo tanto, menos precisa del *modus operandi* (en adelante MO) del delincuente (Stangeland, 2005). Estos perfiladores tienden a enfocarse únicamente en las funciones de decaimiento de distancia integradas en las herramientas de perfiles y en los lugares de los delitos, sin considerar el contexto geográfico, el tipo de delito o el tipo de delincuente.

Dada la escasez de investigaciones, no contamos con evidencia empírica suficiente para llegar a una conclusión firme sobre su utilidad (Emeno et al., 2016). De hecho, la efectividad del perfilado geográfico suele estar corroborada por evidencia anecdótica que presenta una historia de

éxito de la exactitud de un perfil geográfico generado, parece en gran parte debido a la notificación selectiva de casos exitosos, mientras que el número de perfiles construidos sin porcentaje éxito sigue siendo desconocido.

Es probable que los perfiles con alta precisión sean solo la punta del iceberg, dejando a la mayoría de los perfiles geográficos en un ámbito de eficacia indeterminada, que han sido el foco de un creciente cuerpo de investigaciones (Lino et al., 2018; Spaulding y Morris, 2023; Synnott et al., 2019; Yokota et al., 2017). A menudo, los perfiladores geográficos muestran una confianza desmedida en la eficacia de sus métodos, pasando por alto las controversias científicas que los rodean (Kocsis y Palermo, 2015).

Es evidente que cualquier método de elaboración de perfiles delictivos debe descartarse si no es efectivo (Turvey, 2016). La relevancia y el impacto de las técnicas de perfilado geográfico se destacaron claramente en el litigio de Rossmo contra la Junta de Policía de Vancouver en 2001. En este caso, el Departamento de Policía de Vancouver (VPD) cuestionó la validez y eficacia de los métodos de perfilado geográfico desarrollados y empleados por el Dr. Kim Rossmo (LePard, 2010).

En anteriores ocasiones, Rossmo obtuvo reconocimiento público por la aplicación de su modelo a casos ya solucionados donde el delincuente era conocido. Sin embargo, hay que señalar que estos antecedentes podrían haber influenciado los resultados debido a la naturaleza retrospectiva de la técnica del perfil geográfico propuesta por Rossmo (Turvey, 2016).

Un caso ilustrativo es el del violador de Lafayette South Side (Rossmo, 2000), donde el perfil geográfico ubicó la dirección del violador dentro del 2,2% más probable (0,5 millas) de su área de acción.

En primer lugar, se observa que este tipo de perfiles frecuentemente infringe las normas establecidas para el análisis de comportamiento. La evidencia recopilada durante la investigación se evalúa predominantemente desde una perspectiva espacial, descuidando su contexto conductual y emocional. A pesar de que Rossmo ha destacado las virtudes y éxitos del perfilado psicológico, los algoritmos de los programas de perfilado tienden a no incorporar este enfoque psicológico, posiblemente también por la ausencia de una base científica sólida para dicho perfilado (Mordowa, 2019).

Una de las principales razones por las que la elaboración de perfiles geográficos solo ha tenido un cierto éxito se basa en la falta de investigación que analice la racionalidad detrás de la situación geográfica del comportamiento de los delincuentes. Después de todo, el principal supuesto de la elaboración de perfiles geográficos sigue siendo idea de que los delincuentes se mueven de la misma manera dependiendo de sus métodos de ataque, tipo de delito, e incluso características de la escena del crimen (Rossmo, 2000), lo que implica que la serie los delincuentes muestran cierta racionalidad conductual, al menos en sus movimientos espaciales (Phoenix, 2014).

Como regla general, la precisión de un perfil geográfico depende de la cantidad y la exactitud de los datos introducidos en un programa de software. En la práctica, los datos a menudo no están disponibles o son inexactos debido a una investigación realizada descuidadamente (Sammons y Putwain, 2018).

Además, la teoría de la elaboración de perfiles geográficos se deriva en gran medida del análisis de robos y otros delitos contra la propiedad, por lo que su aplicación a mayor escala a los delitos interpersonales puede no ser sostenible. De manera similar, un cambio de lugar del delito resultante de una interrupción o un cambio de oportunidad puede no proporcionar una visión significativa del delincuente, porque la elección de dónde cometer el delito no la toma

completamente el delincuente y, por lo tanto, no refleja su “mapa mental”. También es posible que el lugar del delito se identifique incorrectamente o que no se denuncien los delitos (Ainsworth, 2001).

Entre las primeras limitaciones de la aplicación de un perfil geográfico, se basa en la tipificación del comportamiento de viaje de un delincuente, según varios autores (Canter y Larkin, 1993; Kocsis y Irwin, 1997; Paulsen, 2006; Rossmo, 2000) los perfiladores geográficos al menos están de acuerdo en que un perfil geográfico solo debe hacerse si el autor es un merodeador (véase capítulo 12).

Desde una situación operativa el uso del perfil geográfico se basa en las pruebas que la policía pueda saber antes de que se identifique al delincuente (Canter, 2011).

De acuerdo con Rossmo (2005a), la perfilación geográfica únicamente es viable cuando se satisfacen las siguientes cinco condiciones:

1. El infractor ha cometido un mínimo de cinco delitos (una de las cuestiones más discutidas, y en la que se percibe mayor diversidad de opiniones. Existe un acuerdo común en que cuanto mayor sea el número de delitos en la ecuación, mayor será la precisión, y la media de delitos aceptados, como mínimo, oscila entre los 3 y los 5),
2. Los delitos están relacionados con el mismo delincuente y la serie es relativamente completa (la vinculación de la serie de delitos a un mismo autor han de llevarse a cabo mediante la obtención máxima posible de evidencias forenses. El MO es otra de las cuestiones a considerar para la vinculación de la serie de delitos, si bien se advierte que éste puede variar por diversas circunstancias, de manera que ha de interpretarse con riguroso cuidado y combinándolo con otros factores que, en

conjunto, den credibilidad máxima a la conexión entre delitos (Bartol y Bartol, 2013).

3. El delincuente que cometió los delitos no se ha trasladado al área de actividad delictiva.
4. El delincuente no ha movido los puntos de anclaje (u operado desde múltiples puntos de anclaje) durante su serie de crímenes.
5. La distribución de objetivos adecuados (es decir, el objetivo telón de fondo²) es relativamente uniforme en la casa del infractor.

Sin embargo, Emeno et al. (2016), afirman que con frecuencia se elaboran perfiles geográficos a pesar de que se incumplen una o varias condiciones en el momento de la investigación, por ejemplo, que el delincuente haya trasladado los puntos de anclaje o que se desplace. Esto es motivo de preocupación porque errores como la omisión de una de las condiciones pueden afectar a la precisión del perfil geográfico, por lo que no será tan útil en una investigación (Rossmo, 2005). Además, cabe preguntarse por qué los creadores de perfiles infringen las condiciones, y los investigadores han descubierto que a menudo la razón se debe a la falta de formación o experiencia (Emeno et al., 2016).

² El término telón de fondo se emplea para referirse a la superficie de oportunidad delictiva, esto es, al marco espacio-temporal donde el delincuente tiene oportunidad de cometer sus delitos. Cuando esta superficie no es continua (por ejemplo, cuando la zona de acción de un delincuente serial está situada cerca de un mar o un lago), esta información ha de ser utilizada para ajustar el perfil (Rossmo y Summers, 2015). No obstante, al trabajar con distancia en red, este error se corrige automáticamente (véase capítulo 14).

Las investigaciones sugieren que en la mayoría de los casos en los que el método ha demostrado ser inexacto, lo más probable es que el perfil haya sido generado por una persona no capacitada (Öhrn, 2016).

Emeno et al. (2016), llevaron a cabo una encuesta transversal entre especialistas capacitados de ocho países. Llegando a la conclusión que la violación de principios metodológicos influye en la utilidad de los perfiles para la investigación y contribuye para reducir la confianza de los investigadores en todo el método de elaboración de perfiles.

En octubre de 2002, las autoridades del FBI recurrieron a Rossmo para que ayudara en el caso del francotirador del área de Washington D.C. (John Allen Muhammad y John Lee Malvo). En ese momento, Rossmo trabajaba en Washington D.C. como director de investigación para la *Police Foundation*, una agencia privada sin fines de lucro que capacita a los departamentos de policía en estrategias de aplicación de la ley. Todas las suposiciones de su software se pusieron a prueba públicamente en un caso que no se había resuelto, y el resultado fue un fracaso (Grierson, 2003).

En el caso del francotirador, (el algoritmo de Rossmo) simplemente no pudo adaptarse al nivel de variación en los datos. Como señala Ned Levine, los dos hombres detenidos en el caso del francotirador, John Allen Muhammad y John Lee Malvo, nunca mantuvieron un domicilio fijo por mucho tiempo (Habían vivido recientemente en el estado de Washington). Las distancias que recorrieron eran tan grandes que los modelos eran imprecisos (Grierson, 2003).

En el caso del francotirador, la cuarta condición no fue aplicada por Rossmo, ya que no se puede validar en el caso de una investigación en curso, sin ningún conocimiento del infractor o un sospechoso.

Las condiciones expresadas por Rossmo han sido sometidas a críticas, especialmente por Levine (2005), quien realiza ciertos comentarios ante las condiciones que exige Rossmo para poder perfilar el caso geográficamente. Así, Levine afirma, con respecto al número de asesinatos, que poner el corte mínimo en cinco delitos no es adecuado. Más concretamente expresa:

“Las muestras pequeñas tendrán un error muy grande. Pero ¿por qué establecer el mínimo en cinco? Un tamaño de muestra de cinco crímenes es demasiado pequeño [...] He encontrado un error promedio de más de cinco millas con un tamaño de muestra de cinco asesinatos. Sólo cuando la muestra se incrementó en más de diez casos el error típico descendió a una distancia aceptable de dos o tres millas. En otras palabras, como cualquier procedimiento de muestreo, cuanto mayor sea la muestra, más exacta será la estimación. Pero, si la técnica no es confiable hasta al menos diez o más casos, ¿qué nos dice esto sobre la validez del método? ¿Cuántos casos en serie involucran diez o más incidentes conocidos? Tal vez este método sólo se puede utilizar cuando hay un número considerable de casos” (Levine, 2005, p.2).

La investigación de Snook et al. (2005), también refutan la afirmación de Rossmo citando una falta de sustento empírico sustancial del criterio. Sin embargo, una investigación de Kent y Leitner (2007), que reproduce el trabajo de Newton (1988) sobre asesinatos en serie, ha demostrado que las predicciones del “refugio” de un delincuente (por ejemplo, una base de operaciones o un punto de anclaje) se vuelven sucesivamente más preciso después de la quinta infracción de una serie de datos sobre robos urbanos (véase capítulo 10).

Emeno et al. (2016), proponen otra condición al indicar que la elaboración de perfiles geográficos es más adecuada para los delincuentes con una tipología delictiva de merodeador. Esto se debe a que las investigaciones muestran que los perfiles que constan de viajeros actualmente tienen poca precisión en comparación con merodeadores (véase capítulo 12).

La integridad siempre se evalúa durante un tiempo específico. Como regla general, este tiempo corresponde al momento en que comienza el perfil geográfico. Pero la serie no es estática y se expande mientras el delincuente no sea arrestado o decida voluntaria o involuntariamente detener sus acciones. Entre los criterios de Rossmo (2000) para aplicar la perfilación geográfica, está la pregunta central de una serie precisa y razonablemente completa. En la práctica, puede resultar imposible controlar estos criterios, ya que la serie se encuentra en constante evolución.

La elaboración de perfiles geográficos puede ayudar a reducir la búsqueda del delincuente, pero su dependencia de las ubicaciones puede ser problemática. Dado que el perfil geográfico depende de una serie de delitos, las diferentes escenas del delito deben estar vinculadas a un solo delincuente. El proceso mediante el cual se determina esto se denomina, Análisis Comparativo de Casos (en adelante CCA) , un método para comparar datos de delitos y luego vincular los delitos por su MO (Rossmo, 2000) o, como lo denominan Canter y Youngs (2008), por similitudes en dominios de comportamiento. Las similitudes en el MO y la firma son luego determinadas por los investigadores o el perfilador. La inclusión de un delito no relacionado o la exclusión de uno relacionado afecta la distribución de la búsqueda, sesgando el área hacia una zona inexacta. Esto es vulnerable a problemas de ceguera de vinculación por lo que, debido a la falta de intercambio de información, no todos los sitios de delitos disponibles se incluyen en el análisis (Holmes y Holmes, 1998).

Lo que genera una fuente importante de incertidumbre y posibles errores es el vínculo entre delitos para construir una serie. La confiabilidad de la serie es una función de la evidencia del delito que respalda los delitos cometidos por un solo delincuente.

Por lo tanto, si los cambios en las distancias tienen lugar durante el comienzo de la serie real, es posible que no se pueda distinguir de la serie posiblemente incompleta conocida por la policía.

Un problema de poner a prueba ciertas hipótesis es que a menudo no está claro que la policía haya registrado todos los delitos que forman parte de una serie (Guptill y Morrison, 1995).

Canter señala que la calidad de los datos proporcionados por la policía es una de las principales deficiencias en la elaboración de perfiles geográficos. Sin embargo, otro factor limitante podría ser el estado incipiente en que se encuentra el perfilado geográfico en sí. En esta discusión, argumentamos que el perfilado geográfico podría ser más valioso para las autoridades si se integran variables adicionales y relevantes al proceso. No se debería depender exclusivamente de un programa informático, ya que suelen ofrecer resultados parecidos. Es fundamental incorporar al análisis, información sobre las características pertinentes del delincuente, la naturaleza del delito y la geografía del área delictiva y sus inmediaciones (van Der Kemp y van Koppen, 2007). Además, es plausible sugerir que un perfilador geográfico visite personalmente la zona del delito y los lugares relacionados antes de crear un perfil, proporcionando una visión más detallada del comportamiento del delincuente.

La actual metodología de decaimiento de distancia, utilizada en muchos programas de perfilado geográfico, también enfrenta críticas debido a su dependencia de estructuras espaciales homogéneas. Estas pueden eclipsar detalles sutiles pero cruciales asociados con el desplazamiento del delincuente. Así, muchos perfiles geográficos actuales no evalúan de manera eficaz la influencia del entorno en la comisión de un delito. Contrario a la idea de un espacio isotrópico, la mayoría de las relaciones entre el domicilio del delincuente y los lugares del crimen se

desenvuelven en superficies anisotrópicas, las cuales están moldeadas tanto por elementos físicos como culturales (Kent y Leitner, 2007).

En conclusión, no hay duda de que la elaboración de perfiles geográficos es una herramienta viable que puede identificar a los infractores, si se utiliza correctamente. Esta parece ser la respuesta clave para los académicos y profesionales que cuestionan la elaboración de perfiles geográficos. No se trata simplemente de poner una *X* en un mapa, sino que requiere un investigador altamente capacitado y experimentado para analizar varios factores individuales y ambientales antes de que se pueda generar un perfil preciso.

Chainey (2019), indica que el proceso involucrado en la creación de un perfil geográfico implica mucho más que introducir ubicaciones en una aplicación de software y ejecutar una aplicación que genera un mapa a partir de estos puntos de datos. En primer lugar, se requiere una evaluación del caso, y la ubicación de cada delito para garantizar que los datos sean adecuados y utilizables. A continuación, se requiere una evaluación del vínculo entre los delitos para asegurarse de que el analista está satisfecho con el vínculo entre los sitios del crimen que han hecho otros, o analizar por sí mismos el vínculo. Esto puede resultar en que el analista decida que ciertos delitos definitivamente no están vinculados o que identifique delitos que otros pasaron por alto y que muestran un alto grado de certeza de estar vinculados.

La revisión de los datos implica analizar las características del MO de cada delito, la distribución geográfica de la serie delictiva y los patrones temporales de la serie, tales como cuándo tuvieron lugar los delitos según la estación, día de la semana y hora del día. Es esencial que, al analizar una serie de delitos, el analista se plantee cuestiones clave como:

¿Qué factores podrían haber influenciado la decisión del delincuente respecto a dónde cometer el delito, teniendo en cuenta riesgos y esfuerzos?

¿Es probable que el delincuente se desplazara una corta distancia hasta el lugar del delito, indicando que podría ser local?

Estas son solo dos de las 28 preguntas propuestas por Chainey (2019), que se derivan del programa de formación del software *Rigel Analyst* y que buscan guiar la interpretación de cualquier mapa de perfil geográfico.

Además de los enfoques estadísticos, los perfiladores geográficos también ponderan factores como la probable motivación del delincuente y las características del entorno donde se cometió el delito. Estos elementos pueden influir en el trayecto que un delincuente toma hacia su objetivo y, por ende, alterar la precisión de los modelos estadísticos (Jackson y Bekerian, 1997).

Es fundamental destacar que Rossmo (1997; 1998) enfatiza la importancia de integrar el perfil psicológico con el geográfico, con el fin de afinar la búsqueda y reinsertar elementos subjetivos en el análisis.

Aunque el perfil conocido como *Criminal Geographic Targeting* (en adelante CGT) ofrece una "superficie de probabilidad que indica la posible ubicación del hogar del delincuente", su utilidad puede ser cuestionada. A pesar de que este método ofrece puntos de búsqueda al introducir en el software las ubicaciones de las víctimas, el algoritmo original de Rossmo (1998a) patentado el 14 de julio de 1988, ha tenido pocas modificaciones desde entonces. De hecho, la única variación registrada, el 16 de julio de 2002, se refiere a un ajuste gramatical y no a un cambio sustancial en la fórmula.

La herramienta diseñada para el perfilado geográfico se sustenta en teorías y supuestos derivados de estudios con grupos de delincuentes, que no siempre se aplican a casos individuales, como es el caso de la teoría del decaimiento de la distancia. Si bien estos métodos proporcionan herramientas valiosas para prever matemáticamente áreas probables de los puntos clave de los

delincuentes (como su hogar o trabajo), poseen limitaciones. Uno de sus principales inconvenientes es que presuponen, de forma predeterminada, una distribución uniforme de objetivos en el área de búsqueda (Kent y Leitner, 2009).

Además, estas herramientas no consideran las variables ambientales presentes en el área de actividad del delincuente. Tampoco tienen la capacidad de discernir si la serie de delitos fue cometida por un merodeador en una zona específica o por alguien que se desplaza continuamente (viajero).

3. Dimensiones

Para una mayor claridad en el desarrollo de esta investigación, tras la introducción, se detallarán tres dimensiones del perfilado geográfico. No obstante, la dimensión espacial constituye el núcleo central de la tesis doctoral.

3.1 Espacial

El enfoque geográfico e interés por la investigación del delito han aumentado significativamente en las últimas décadas debido al hecho de que el delito no puede separarse del natural del hábitat del delincuente. Desde finales de la década de 1970 se ha reconocido que existe un aspecto espacial asociado con el delito, ya que el delito tiene una cualidad geográfica inherente (Chainey y Ratcliffe, 2005). Los geógrafos se interesaron y comenzaron a estudiar cómo se puede modelar la ocurrencia del delito en un contexto geográfico, para comprender mejor los patrones exhibidos por la distribución del crimen en cualquier lugar o ubicación en particular (Taras, 1996).

Aunque no existen teorías geográficas concretas que expliquen la distribución espacial de la delincuencia, se ha reconocido un vínculo entre la geografía humana y la criminología. Este nexo surge debido al paralelismo significativo que ha prevalecido en la ciencia durante décadas, de manera similar a cómo la criminología estuvo primordialmente centrada en el ámbito de la sociología debido a diversos cambios paradigmáticos (Ksenija y Jelena, 2017).

El interés en el análisis espacial del delito se extiende desde la perspectiva de comprender la etiología del delito y desarrollar métodos y prácticas de justicia penal para reducir el delito (Anselin, 2001). No se limita a los criminólogos, sino que los geógrafos urbanos, los agentes de policía, los analistas de delitos y otros investigadores del sector público y privado han estado interesados durante mucho tiempo en la dimensión espacial del delito (Gaile y Willmott, 2003).

Daele y Bernasco (2012), distinguen tres aspectos del *Journey to crime* (en adelante JTC) que pueden caracterizarse por la consistencia; destino, distancia y dirección. El destino de una infracción es la ubicación geográfica donde tiene lugar. La distancia es la distancia euclidiana o en línea recta entre la casa del delincuente y el destino. La dirección es el ángulo entre la línea de ataque local y una referencia de línea de base. El destino es el aspecto más informativo, ya que implica tanto la distancia como la dirección desde casa.

3.2 Temporal

El tiempo junto con el espacio son las dimensiones de la realidad donde se desarrollan las acciones humanas. La incorporación del estudio del tiempo y de los cambios temporales a escala de la vida cotidiana ha tenido gran trascendencia en geografía, especialmente en estudios como los de Carlstein et al. (1978), que enfatizan la importancia del tiempo en el estudio de los problemas espaciales.

Aunque existe una amplia literatura académica sobre asesinos en serie, se ha prestado poca atención al componente clave de la intermitencia en la delincuencia, definido como los intervalos de tiempo entre asesinatos, conocidos como períodos de enfriamiento. Hasta el momento, no existe una línea de base estadística ni investigación empírica que muestre claramente qué factores influyen directamente en la duración del período de enfriamiento, en relación con los estudios realizados por (Edelstein, 2019; Lange, 1999; Osborne y Salfati, 2015; Schlesinger et al., 2017; Simkin y Roychowdhury, 2015). Por otro lado, se ha encontrado que el período de enfriamiento es universal, lo que sugiere que cumple alguna función latente, según Osborne y Salfati (2015); en otras palabras, este período facilita o preceden al próximo asesinato, como lo señalan (Douglas et al., 1986; Edelstein, 2015; Fox y Levin, 2001; Holmes y Holmes, 1998). El término “enfriamiento” no solo describe un período temporal, sino que también se refiere a un período de equilibrio

emocional en el que el delincuente retorna a un estado de normalidad, según Kraemer et al. (2004), o el tiempo de descanso psicológico entre incidentes, que podría considerarse un período de preparación depredadora, como menciona Ramsland (2005).

Desafortunadamente, los determinantes cognitivos de las motivaciones de los asesinos en serie probablemente sean altamente idiosincrásicos y difíciles de conocer o predecir y por lo tanto conocer la probabilidad de búsqueda de un nuevo objetivo. Por lo tanto, un enfoque de la elección racional no explica por qué los asesinos en serie se motivan a matar una y otra vez, ni predice ninguna secuencia temporal en particular. Más bien, la teoría implica que el comportamiento temporal de los asesinos en serie debería mostrar signos de caos, ya que se espera que este comportamiento sea cada vez más impredecible con el tiempo (Lange, 1999). En particular, el tiempo caótico significa que no hay posibilidad de definir el orden temporal e implica una ruptura de la causalidad.

La metáfora del caos, basada en los modelos matemáticos y los aspectos psicológicos de la conducta humana, proporciona una visión útil para describir la complejidad del comportamiento humano analizada tanto desde un prisma individual como colectivo (Forno y Merlone, 2013).

La figura 2-1 presenta un gráfico temporal que ilustra el número acumulado de asesinatos perpetrados por Peter Sutcliffe durante sus 1962 días de actividad. Se observa una marcada irregularidad, con largos intervalos de tiempo sin ningún asesinato, interrumpidos por abruptos incrementos cuando perpetró múltiples homicidios en un corto período. Este patrón sigue una curva matemática conocida como " *Devil's staircase* " (Dovgoshey et al., 2006). Caracterizamos esta escalera mediante las distribuciones de las longitudes de paso. En nuestro análisis del patrón temporal de la actividad de un asesino en serie que cometió 20 homicidios en un lapso de doce

años, identificamos claramente la presencia de una "Escalera del diablo" en la trama del número acumulado de asesinatos en función del tiempo.

La representación gráfica de los asesinatos de Peter Sutcliffe evidencia cómo el total de sus homicidios aumentó a lo largo del tiempo. El periodo abarca desde su primer asesinato el 07/05/1975 hasta su detención el 11/17/1980, con intervalos entre homicidios que variaron desde 10 días hasta 502 días.




Figura 2-1: La escalera de Peter Sutcliffe, ilustra cómo el número total de sus asesinatos aumentó con el tiempo. Las marcas principales en el eje horizontal están separadas por 200 días y las del eje vertical indica el número acumulativo de asesinatos.

3.3 Cognitiva

La tercera dimensión de los perfiles geográficos son los mapas mentales; también conocidos como "zonas de actividad conductual". Estos mapas, provenientes de la psicología cognitiva, buscan ofrecer una estructura teórica para entender cómo el ser humano almacena,

procesa y emplea la información. durante sus actividades cotidianas. Los mapas mentales son representaciones individuales que reflejan la percepción de nuestro entorno inmediato y las interacciones diarias con él. Estas representaciones actúan como estructuras mentales que nos permiten adquirir, retener y recuperar información sobre posiciones y características de fenómenos en nuestro alrededor (Kaplan et al., 2017). Según Poliřenská (2013), estos mapas mentales ilustran comportamientos espaciales, decisiones sobre la elección de rutas, orientación en el entorno y otros procesos de toma de decisiones.

Este principio sugiere que todos los delincuentes forman algún tipo de "imagen cognitiva" de sus áreas locales con las que están familiarizados (Rossmo, 1996). Estos mapas o imágenes mentales pueden representar la ubicación de los hogares; lugares de trabajo, centros de recreación y centros comerciales (Holmes y Holmes, 1994).

Capítulo 3

SISTEMAS DE INFORMACIÓN GEOGRÁFICA

En general, un Sistema de Información (en adelante SI) consiste en la unión de información en formato digital y herramientas informáticas (programas) para su análisis con unos objetivos concretos dentro de una organización. Un Sistema de Información Geográfica (en adelante SIG) es un caso particular de SI en el que la información aparece georreferenciada, es decir incluye su posición en el espacio utilizando un sistema de coordenadas estandarizado (Sarría, 2014).

Un SIG o GIS, en su acrónimo inglés (*Geographic Information System*) es una integración organizada de hardware, software y datos geográficos diseñada para capturar, almacenar, manipular, analizar y desplegar en todas sus formas la información geográficamente referenciada con el fin de resolver problemas complejos de análisis espaciales.

Desde las exploraciones iniciales, como la realizada por Glyde (1856), se ha evidenciado que la delincuencia manifiesta notables diferencias según la geografía. Esta característica ha llevado a que las técnicas de mapeo se conviertan en herramientas esenciales para analizar y representar la incidencia del crimen. Por ejemplo, Shaw y McKay (1942), emplearon estas técnicas en su estudio pionero sobre la delincuencia juvenil en Chicago. De forma similar, Baldwin y Bottoms (1976), recurrieron a la cartografía para analizar la distribución del crimen en Sheffield, destacando el papel crucial de la tenencia de vivienda en la delincuencia. A pesar de la relevancia de estos estudios, las metodologías que utilizaron se consideran básicas, comparadas con las herramientas actuales. Con la irrupción de los sistemas de SIG y el acceso a datos detallados a

nivel individual, el análisis geográfico ha experimentado una evolución significativa. Esto ha permitido el desarrollo de técnicas más sofisticadas, como la identificación de "zonas de alta incidencia delictiva", propuesta por Grubestic y Murray (2001).

Con respecto al perfil geográfico, gran parte del enfoque de la investigación se ha centrado en el desarrollo de modelos matemáticos y aplicaciones informáticas para predecir la base de operaciones de un delincuente o los puntos de anclaje (Canter y Youngs, 2008).

La expansión de las tecnologías ha impulsado una difusión sin precedentes de métodos espaciales, consolidando aún más la importancia de la disciplina geográfica. Es particularmente en los SIG donde los datos espaciales adquieren un significado social primordial, respaldando investigaciones que influyen en políticas y en procesos de toma de decisiones. Esta singularidad coloca a los SIG en una encrucijada, oscilando entre la rigurosa exactitud del pensamiento científico y el ámbito más ambiguo y subjetivo del discurso humano. Aunque este posicionamiento otorga a los SIG una ventaja única para interactuar con el público y los responsables de decisiones, también conlleva peligros, particularmente en cuanto a su mal uso e interpretación posible errónea (Goodchild y Haining, 2004).

Varios autores han ofrecido una panorámica sobre las principales aplicaciones de la tecnología de información geográfica en el análisis y predicción de delitos, con un enfoque principal en los países anglosajones (Chainey y Ratcliffe, 2005; Lin y Eck, 2008).

Wang (2012) profundizó en seis áreas clave de aplicación de los SIG en la aplicación de la ley. Estas áreas abarcan desde la investigación y prevención del crimen hasta técnicas más avanzadas. Wang enfatizó la relevancia de la sinergia entre disciplinas académicas como la criminología, geografía, informática y estadística, y la colaboración con empresas y especialistas del sector. Gracias a esta interacción multidisciplinaria, las aplicaciones de SIG han avanzado

desde la mera representación cartográfica de delitos hasta el desarrollo de análisis espaciales especializados y su integración en modelos predictivos avanzados.

El análisis geográfico alcanzó su máximo potencial a principios de la década de 1990, gracias a los avances en la informática. Estos progresos tecnológicos no solo permitieron a los investigadores visualizar geográficamente los lugares de los delitos, sino que también les facilitaron analizar la actividad delictiva en diferentes contextos.

Con la implementación de los SIG, se pudieron registrar y contrastar datos específicos en relación con otras variables. Esta integración del análisis espacial, las técnicas estadísticas y la generación de informes dotó a los analistas criminales de herramientas esenciales para detectar variaciones, identificar patrones y tendencias, y diseñar estrategias efectivas de mitigación.

Actualmente existen muchas alternativas de software que pueden ser usadas para analizar el comportamiento espacial de la actividad delictiva. Este gran conjunto de herramientas puede dividirse en dos categorías: herramientas de software SIG no especializadas en el delito y herramientas de software SIG especializadas en el delito.

Las herramientas de software SIG no especializadas en el delito permiten realizar la creación, edición, el procesamiento y el análisis de información correspondiente a diversa información delictiva, así como cualquier otro tipo de información (Arenas, 2013). Este uso masivo se debe a que estas herramientas cumplen con muchas de las funcionalidades necesarias para el análisis del crimen (*International Association of Crime Analysts*, 2012). De acuerdo con Dempsey (2016), dentro de las herramientas más populares se encuentran: ArcGIS, MapInfo, GeoDa, Geomedia, Maptitude, entre otros.

Las herramientas de software SIG especializadas en el delito permiten realizar funciones analíticas para administrar datos, realizar análisis estratégicos y tácticos e investigar patrones

delictivos, dentro de las herramientas más populares se encuentran: ArcGIS Pro (Caja de herramientas de análisis de criminalidad y seguridad) y QGIS (Complemento para el análisis criminológico -Visualist-).

En el marco de las iniciativas del Comité *Standards, Methods y Technology* (en adelante SMT) de la Asociación Internacional de Analistas de Crimen (en adelante IACA), se elaboró un documento clave con el objetivo de orientar las necesidades de software específicas para el mapeo del delito, enfocándose particularmente en los SIG. Este documento sirve como una guía esencial para analistas criminales, administradores y otros responsables de la toma de decisiones, ofreciéndoles directrices claras para optimizar el uso de los SIG en el análisis de actividades delictivas (Overland Park, 2012).

3.1 SIG Especializado en Perfilado Geográfico.

Las herramientas de software SIG especializadas en perfilado geográfico son muy variadas y sus esfuerzos están orientados a atender las necesidades de los usuarios teniendo en cuenta dos factores: el tipo de actividad delictiva y la metodología empleada para analizarla.

Al desarrollar una metodología de evaluación de esta herramienta, el *National Institute of Justice* (en adelante NIJ) convocó a un grupo de expertos de las diversas funciones implicadas en la elaboración de perfiles geográficos para abordar diversas consideraciones metodológicas (Rich y Shively, 2005), centrándose en cuatro aplicaciones de software de elaboración de perfiles geográficos: CrimeStat (Levine, 2015), Dragnet (Canter, 1995), Predator (Godwin, 2001b) y Rigel (Rossmo, 1997c). Cada una de estas aplicaciones de software se resume en este capítulo. Cabe

señalar que difieren en muchos aspectos, lo que debería esperarse porque se desarrollaron para diferentes propósitos y destinatarios.

Rigel

En una serie de artículos, Rossmo (1997a; 1995) expuso un método matemático para determinar la ubicación base de un delincuente en serie, basándose en la distribución de los incidentes. Este enfoque matemático es una adaptación del modelo de área de búsqueda propuesto por Brantingham y Brantingham (1981). En este modelo, se asume que el comportamiento de búsqueda del delincuente obedece a una función que disminuye con la distancia, presentando menor actividad cerca de su base del delincuente.

En su trabajo, "*Geographic Profiling*", Rossmo (2000) presenta un enfoque basado en el algoritmo de focalización criminal geográfica (en adelante CGT, por sus siglas en inglés: *Criminal Geographic Targeting*)

El modelo CGT utilizado por Rigel (Rossmo, 1997c) analiza los patrones de las ubicaciones relacionadas con un caso criminal y genera una superficie de probabilidad que indica dónde es más probable que el autor resida.

El modelo CGT desarrolló un precedente para futuros sistemas de perfilación al integrar fundamentos teóricos, especialmente al incorporar el concepto de zona de amortiguamiento en sus predicciones. Este modelo se desarrolla en cuatro etapas esenciales:

1. Se define un área de estudio rectangular que se extiende más allá del área de los incidentes cometidos por el delincuente en serie (estas se basan en coordenadas proyectadas; presumiblemente, las direcciones tendrían que ajustarse si se usaran coordenadas geográficas), calculando la diferencia media entre todas las escenas

del crimen en las coordenadas X e Y . Posteriormente se añade la mitad de la distancia media calculada a la coordenada Y más alta de todos los delitos y resta el mismo número de la coordenada Y más baja. El procedimiento se repite con las coordenadas X más alta y baja.

2. El estudio rectangular define una cuadrícula a partir de la cual se pueden definir columnas y filas, compuestas por 40.000 celdas (véase capítulo 3.2). La herramienta asume que el delincuente vive al menos en esa área definida (van Der Kemp, 2014). Si bien, el punto de anclaje ha de estar situado en el área de acción del criminal, ya que si su acción delictiva la lleva a cabo fuera de dicha área los programas informáticos serán incapaces de manejar e interpretar adecuadamente las variables contempladas (Koppen y Kemp, 2010).
3. Para cada celda de la cuadrícula, se toma la distancia de Manhattan (distancias ortogonales medidas por cuadrículas cartográficas) a cada ubicación del incidente (véase figura 3-3).
4. Mediante un enfoque matemático (ecuación 3.1), se ha descompuesto la función de disminución de la distancia en dos componentes fundamentales. El primero aborda la noción de que la probabilidad disminuye a medida que la distancia aumenta. El segundo componente se centra en el concepto de una zona de amortiguamiento. CGT suma los valores para producir una puntuación final para cada punto del mapa. Cuanto mayor sea la puntuación resultante, mayor será la probabilidad de que ese punto contenga el punto de anclaje del delincuente.

$$P_{ij} = k \sum_{n=1}^C \left[\phi / (|x_i - x_n| + |y_j - y_n|)^f + (1 - \phi)(B^{g-f}) / (2B - |x_i - x_n| - |y_j - y_n|)^g \right] \quad (3.1)$$

$$\phi_{ji} = \{1, \quad (|x_i - x_n| + |y_j - y_n|) > B$$

$$\phi_{ji} = \{0, \quad \text{de lo contrario}$$

Donde;

ϕ funciona como un factor de ponderación que se establece en 0 para lugares dentro de la zona de amortiguamiento, y 1 para lugares fuera de la zona de amortiguamiento, k es una constante determinada empíricamente como un factor de normalización, ϕ_{ji} permite que P cambie entre los dos términos. Si ocurre un delito dentro de la zona de amortiguamiento, entonces $\phi_{ji} = 0$, y por tanto, el primer término no contribuye al resultado global. Esta es una prerrogativa para definir el primer término en el caso de que la distancia entre un punto (o celda) sea igual a cero. Cuando $\phi_{ji} = 1$, el primer término se utiliza para calcular P_{ij} . B es el radio de la zona de amortiguamiento, que equivale a la distancia media del vecino más próximo, C es el número de los lugares delictivos, g f son exponentes de fricción determinados empíricamente, se determinó el valor del exponente de distancia ($f = 1.2$) a partir de una formulación de un modelo de gravedad para describir patrones de migración interprovincial de delincuentes fugitivos. Presumiblemente, las estimaciones se derivan de una muestra de ubicaciones conocidas de delincuentes, en las que se registra la distancia a cada incidente, como por ejemplo, registros de arresto (Rossmo, 1987). Este mismo exponente se usó para distancias tanto dentro como fuera del radio de la zona de amortiguamiento, es decir $g = f$. El problema con el algoritmo que utiliza Rossmo es que no ha publicado los parámetros de estas dos funciones (van Der Kemp, 2014).

Rigel (Rossmo, 1997), utiliza una función de decaimiento de distancia con una estructura de dos funciones (ecuación 3.1), la primera es una función exponencial lineal positiva y la segunda una función exponencial negativa (figura 3-2). Rossmo no tiene declarado explícitamente en su trabajo publicado sobre Rigel, pero se puede hipotetizar que la función lineal refleja el supuesto de una "zona de amortiguación" (Goodwill et al., 2014).

La función exponencial negativa truncada (figura 13-10) es similar a la función del modelo CGT de Rigel que se representa en el geoperfil de la figura 3-1. La función exponencial negativa truncada es una función formada por dos elementos matemáticos diferentes, la función lineal y la exponencial negativa (Kemp y Koppen, 2007). Para la distancia cercana, se define una función lineal positiva, comenzando con probabilidad cero para la distancia 0 y aumentando hasta d_p , una ubicación de probabilidad máxima. Entonces, la función sigue una exponencial negativa, disminuyendo rápidamente con la distancia. Las dos funciones matemáticas que componen esta función son:

$$\text{Lineal} : f(d_{ij}) = 0 + B^*d_{ij} \text{ para } d_{ij} \leq d_p \quad (3.2)$$

$$\text{Negativa} - C^*e^{-d_{ij}} \quad (3.3)$$

$$\text{Exponencial} : f(d_{ij}) = A^*e^{-C^*d_{ij}} \text{ para } d_{ij} > d_p \quad (3.4)$$

Donde d_{ij} es la distancia desde la base de operaciones, B^* es la pendiente de la función lineal y para la función exponencial negativa A es un coeficiente y C^* es un exponente. Dado que la función exponencial negativa solo comienza a una distancia particular, se supone que d_p , A , es la intersección del eje Y . De manera similar, la pendiente de la función lineal se estima a partir de

la distancia máxima, d_p , mediante una función de probabilidad máxima. Los valores predeterminados son 0.4 para la distancia máxima, d_p 13.8 para la probabilidad máxima y 20.2 para el exponente, C .

Esta función es la aproximación más cercana al modelo de Rossmo (figura 3-2). Sin embargo, difiere en varias propiedades matemáticas. Primero, la función "cerca de la base de operaciones" es lineal, en lugar de una función no lineal. Asume un simple aumento en las probabilidades de viaje por distancia desde la base de operaciones, hasta el borde de la zona de seguridad. En segundo lugar, la parte de disminución de la distancia de la función es una exponencial negativa, en lugar de una función de distancia inversa; en consecuencia, es más estable cuando las distancias son muy cercanas a cero, por ejemplo, para un delito en el que no hay una compensación (Levine, 2005).

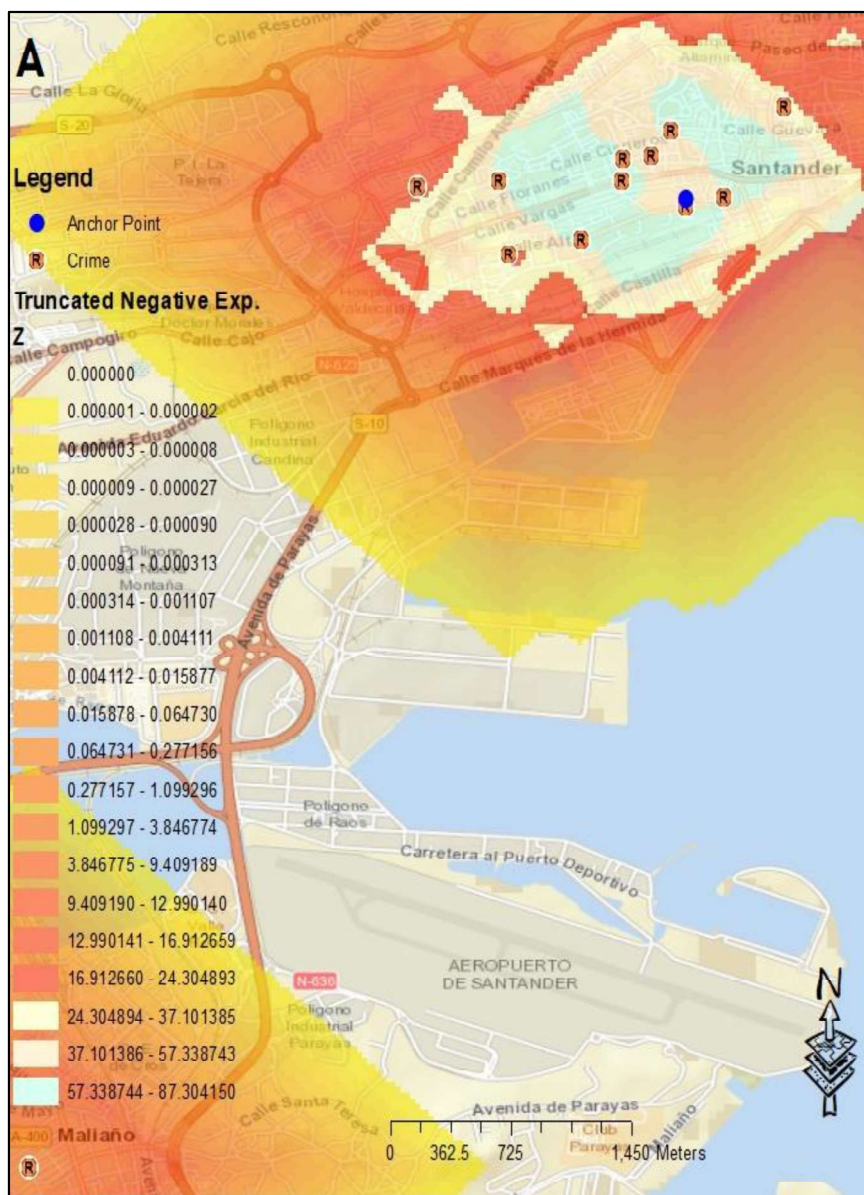


Figura 3-1: Perfil Geográfico basado en el algoritmo *Truncated Negative Exponential*.

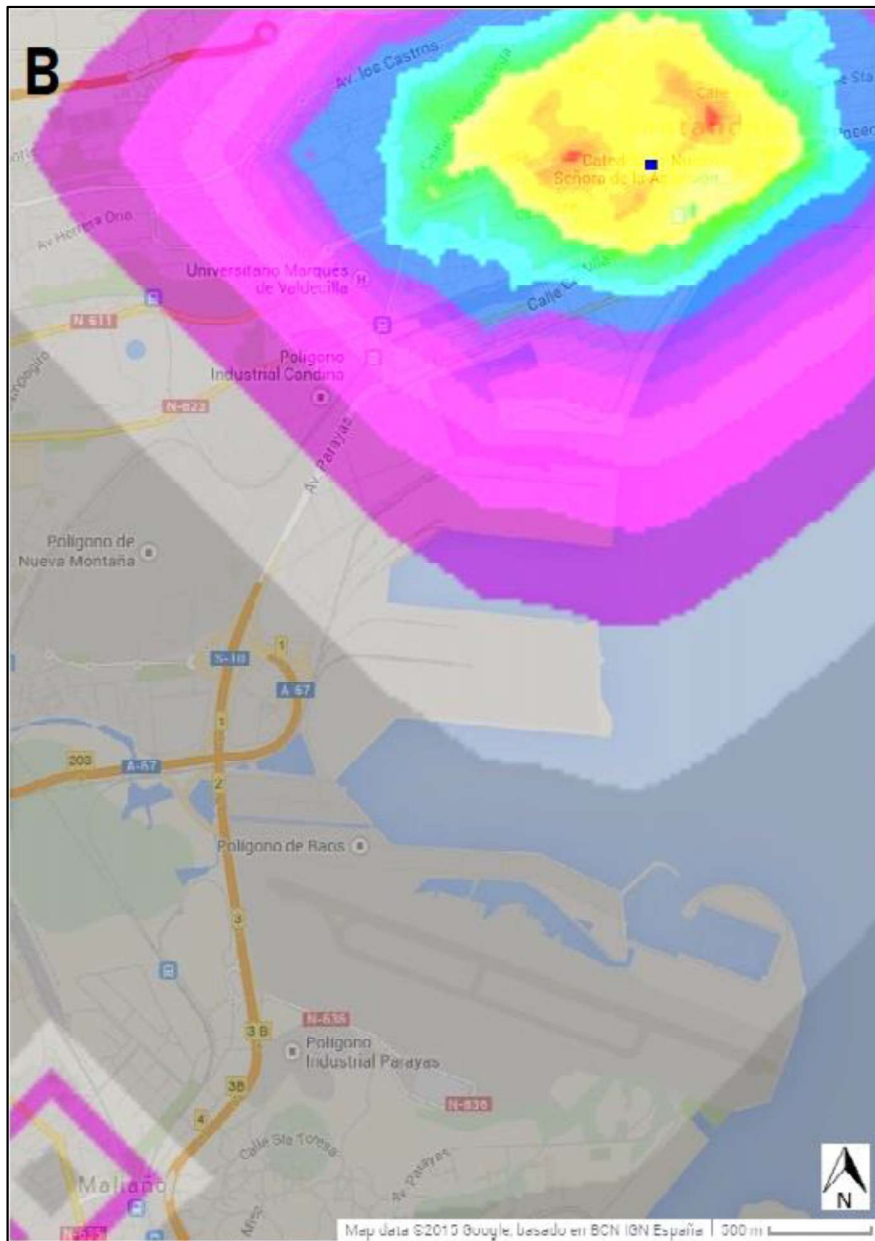


Figura 3-2: Perfil Geográfico basado en el algoritmo de focalización criminal geográfica. Nota: Tomado de *International e-Journal of Criminal Science* (p.17) por Rossmo y Summers, 2015

La figura 3-1 y 3-2 muestra el caso de José Antonio Rodríguez Vega "El Mataviejas", el cual asesinó a 16 mujeres en Santander (España) en los años 1987 y 1988.

Al analizar los modelos, Rigel utiliza un modelo CGT de Rigel, tal como se ilustra en la (figura 3-2), que guarda similitud con la función *Truncated Negative Exponential* representada en la (figura 3-1). A continuación, detallamos los resultados derivados de estos modelos.

En la figura 3-1, se muestra un porcentaje de acierto del 2,6% para la función *Truncated Negative Exponential* en un área de 24,83Km² (40,035 celdas), con una distancia media del vecino más cercano de 213 metros. Esto equivale a 0,62 km² de los 24,83 km² de la denominada "zona de caza".

El domicilio de Rodríguez Vega se indica con un cuadrado azul (figura 3-2), y se encuentra en el 2.6 percentil de la superficie ocupada por el geoperfil (en inglés, nos referimos a este concepto a esto como el *hit score percentage* o HS%, en este caso específico es del 2.6%). Es decir, si se empezara a buscar al delincuente de acuerdo a lo indicado por el geoperfil, empezando por las zonas rojas, luego las naranjas, y así sucesivamente, habría que cubrir 2.55% del área mostrada en la figura 3-2, correspondiente a 0.23 km² de los 22.92 km² de la zona de caza, hasta dar con su domicilio (Rossmo y Summers, 2015).

Fortaleza y debilidades modelo

1. Al evaluar la precisión del sistema CGT, Rossmo (2000) se basó en información de tan solo 13 casos de asesinatos seriales, los cuales involucraron a 15 asesinos en serie, 178 víctimas y 347 localizaciones. Estos 13 episodios fueron seleccionados de un conjunto

más amplio de datos que incluía a "asesinos seriales que habían cometido al menos cinco homicidios después de 1960, con residencia fija, que actuaban solos o con un único cómplice y que mostraban patrones de caza específicos (residencialmente estables). En su investigación, Rossmo (2000) reporta la evaluación de precisión para una muestra específica, no seleccionada al azar, de series de asesinatos. Además, solo se utilizaron las evaluaciones de acierto CGT elegidas de esta muestra para evaluar la precisión del sistema Rigel.

Es importante señalar que la información utilizada no proviene de registros policiales oficiales, sino que fue adquirida de una base de datos disponible en plataformas en línea (Lexus/Nexus) enfocada en asesinos en serie. Dado que el conjunto de datos representa una muestra reducida y específica de delitos, su alcance se ve limitado. Por lo tanto, la generalización de los resultados para otros tipos de delitos y circunstancias es restringida (Paulsen 2006).

De los 19 casos de asesinatos en serie resultantes del procedimiento de muestreo, se seleccionaron 10 para un análisis más detallado; (1) Richard Chase; (2) Albert DeSalvo; (3) Clifford Olson; (4) Angelo Buono and Kenneth Bianchi; (5) Peter Sutcliffe; (6) Richard Ramirez; (7) David Berkowitz; (8) Jeffrey Dahmer; (9) Joel Rifkin; (10) John Collins; Con el fin de explorar el impacto de la violación de determinados criterios de selección, se incluyeron 3 casos adicionales: (11) Aileen Wuornos; (12) Ian Brady and Myra Hindley; y (13) Jerry Brudo.

2. En la evaluación, se tomó en cuenta tanto los lugares donde se encontraron a las víctimas como aquellos donde se descubrieron los cadáveres. La decisión de incluir o

no estos sitios corresponde a un experto con la capacitación adecuada, lo que subraya la importancia de una formación especializada en el uso del sistema. Sin embargo, no hay pruebas empíricas que confirmen que dichas decisiones se tomen de forma racional, incluso por parte de usuarios capacitados. En cuanto al número de escenarios delictivos en la serie de asesinatos analizada, varió, comenzando desde cinco sitios, lo que indica que sólo se considerarán series extensas para el estudio.

Según Laukkanen (2007), las áreas de búsqueda mencionadas en Rossmo (2000) varían desde $0,1 \text{ km}^2$ hasta 1829 km^2 , lo que refleja una predicción notable inestable e imprecisa. Estos desafíos metodológicos ponen en tela de juicio la confiabilidad del método. A pesar del enfoque innovador, el sistema de Rigel, que se basa en él, no ha recibido respaldo a través de pruebas empíricas que confirman su validez científica (Levine, 2004; Snook, Taylor, et al., 2005).

3. Levine y Associates (2013) señala diversas fortalezas y debilidades en el modelo de Rossmo. Una de ellas es que, si bien el modelo se fundamenta teóricamente en el marco de Brantingham y Brantingham (1981) para determinar áreas de búsqueda de delincuentes adoptando modelos matemáticos de gravedad, distingue principalmente dos comportamientos de viaje delictivo: aquellos cercanos al hogar y los que se llevan a cabo más alejados. Aunque la teoría que respalda la fórmula de Rossmo está ampliamente documentada, su aplicación práctica presenta errores. En particular, la fórmula se aproxima a las asíntotas tanto cuando la distancia de la escena del delito es cero (es decir, el punto (xi, yj) coincide con una escena del delito) como cuando un punto se ubica exactamente a una distancia de $2B$ del lugar del delito.

Morrow (2010), sugiere suavizar la fórmula de Rossmo para que se mantenga la

idea de un área de amortiguamiento, pero se elimina el comportamiento asintótico y se aumenta la tolerancia al error. El modelo contiene varios parámetros internos que se pueden cambiar para mejorar el modelo. La mayoría de estos parámetros se establecen en valores que no necesitan cambiar de un caso a otro. Sin embargo, un parámetro muy importante es el área de amortiguamiento. Para determinar el área de amortiguación, se calcula la mitad del promedio de la distancia del vecino más cercano a las escenas del delito. En general, este resulta ser el radio del área de amortiguamiento.

El concepto de zona de amortiguamiento es solo una interpretación de la tendencia de muchos delitos de no cometerse cerca de la ubicación de la casa. Hay otras interpretaciones que son aplicables. El parámetro utilizado en el algoritmo (ecuación 1) de perfilado geográfico para calcular el radio de la zona de seguridad (*buffer zone*) que equivale a (*distance equal to half the mean nearest neighbor distance*). El radio de la zona de amortiguamiento (B) se fijó inicialmente en 0,3 millas (aproximadamente 0,5 kilómetros). Si bien esta fue una estimación razonable para ciertos casos, se hizo evidente que el valor era inapropiado para aquellos delincuentes que operaban en grandes áreas metropolitanas o regionales. En tales casos, la zona de amortiguamiento desapareció efectivamente. Por lo tanto, era necesario definir un radio variable, lo suficientemente flexible para adaptarse a diferentes rangos de movilidad delictiva. El patrón de puntos del sitio del crimen sugirió un enfoque para tal definición: parecía que las distancias entre los puntos podían proporcionar una indicación del tamaño de la zona de amortiguamiento. En consecuencia, el radio se estableció para que fuera igual a la media de la distancia del vecino más cercano (calculado utilizando una métrica de Manhattan). Posteriormente, este valor se

modificó ligeramente para abordar el comportamiento espacial de ciertos delincuentes que cometen delitos tanto cerca como lejos de sus hogares. El radio final de la zona de amortiguamiento se estableció en la mitad de la distancia media del vecino más cercano (Rossmo, 1998).

4. El modelo aporta una rigidez matemática que no puede adaptarse a todas las situaciones. Aunque existen dos funciones que pueden cambiar según el contexto, la función específica de disminución de distancia también puede variar. Al especificar una forma estricta para ambas ecuaciones, se reduce la adaptabilidad del modelo a distintos delitos o contextos donde la disminución de la distancia no coincide con lo propuesto por Rossmo (Levine, 2013).

Martin et al. (2009) llevaron a cabo una investigación enfocada en los factores que determinan la distribución y comportamiento de caza de los tiburones en Seal Island, False Bay, Sudáfrica. En colaboración con el Dr. Rossmo, implementaron la herramienta Rigel (Rossmo, 1997c), optando por el uso de la distancia Manhattan en su algoritmo. Sin embargo, quedó en incertidumbre si esta medida es la más apropiada para estudiar la caza de animales y si se realizaron modificaciones en los parámetros f y g .

El 30 de mayo de 2021, me puse en contacto con el Dr. Rossmo para solicitar la opinión sobre las adaptaciones sugeridas por Le Comber et al. (2006) y Stevenson (2015). Estos autores se inclinaron por el uso de distancias euclidianas en lugar de las de Manhattan, basando su decisión en que las especies biológicas no siempre se adaptan a patrones típicos de desplazamiento urbano, especialmente en Norteamérica.

El Dr. Rossmo compartió su perspectiva, destacando que los animales no cazan siguiendo un camino lineal. Por el contrario, suelen trazar rutas en zigzagueantes, lo que

optimiza su búsqueda. Como sustento, mencionó un estudio sobre patrones de caza de mirlos en prados ingleses (Smith y Sweatman, 1974). Enfatizó la similitud entre este comportamiento y la "caza" llevada a cabo por delincuentes, sugiriendo que las distancias euclidianas pueden no capturar con precisión la realidad del movimiento. Además, indicó que para los parámetros f y g , se adhirieron a las especificaciones del algoritmo CGT (no se modificaron).

Rossmo et al. (2005) argumentan que sería óptimo si estos parámetros pudieran adaptarse automáticamente según el patrón de delitos observados en cada situación particular. La única manera de desarrollar un algoritmo de este tipo y evaluar el impacto de diferentes parámetros en un perfil geográfico, es analizando un amplio conjunto de casos reales. Sin embargo, se debe tomar en cuenta que se trabajó con datos de solo 13 casos de asesinatos en serie, que involucraron a 15 delincuentes.

La propuesta, aunque pueda parecer algo confusa a primera vista (en relación a la caza de tiburones en las que los parámetros f y g no se modificaron) contiene un concepto importante en el análisis de patrones de delitos, al indicar la adaptabilidad de los parámetros en función de las características específicas de los delitos.

5. En términos generales, las soluciones no comerciales permiten que el usuario defina estos parámetros para cada situación, una práctica que puede no ser ideal para herramientas operativas de la policía. Esto implica un riesgo: un analista que desconozca el impacto de los parámetros podría no obtener resultados precisos. Afortunadamente, existen otras herramientas capaces de definir automáticamente los parámetros (Butkovic, 2019).

El uso del modelo CGT también requiere el uso de constantes y exponentes determinados empíricamente. Rossmo no presenta la base para la selección empírica de estos en su trabajo *Geographic Profiling* (Rossmo 2000). El uso de un término de producto, Σ , complica las matemáticas. Es decir, la técnica evalúa la distancia desde una celda de la cuadrícula particular, i , hasta una ubicación de incidente particular, j . Luego multiplica este resultado por todos los demás resultados. Dado que los valores de P son en realidad densidades, que pueden ser superiores a 1 y 0, el proceso, si se aplica estrictamente, sería una combinación de probabilidades con una sobreestimación de la probabilidad de celdas de la cuadrícula cercanas a las ubicaciones del incidente y una subestimación de la probabilidad de celdas de cuadrícula más alejadas. En la descripción del método, sin embargo, Rossmo en realidad menciona la suma de los términos. Por lo tanto, la sustitución de un signo de suma, Σ , por el signo del producto podría beneficiar los cálculos matemáticos.

6. Levine (2013), identifica varios límites al modelo de Rossmo, entre otros: el uso exclusivo de la distancia de Manhattan (ecuación 3.5), esta inestabilidad del modelo para un área de amortiguamiento cercana a una distancia nula, el supuesto isotrópico. Al utilizar la métrica de Manhattan para representar distancias entre puntos (figura 3-3), se asume un patrón de movimiento a lo largo de los bordes de las celdas de la cuadrícula para el infractor, lo que puede ser válido para las ciudades que tienen una red de calles rectangulares. Sin embargo, muchas ciudades europeas tienen una combinación de diferentes formas de redes de calles que no siguen una cuadrícula perfecta. En estas ciudades, el uso de la distancia de Manhattan conduce a una sobreestimación.




Figura 3-3. Métrica Manhattan y euclidiana para representar distancias entre puntos

La distancia Manhattan entre puntos $x = (x^{(1)}, x^{(2)})$ y $y = (y^{(1)}, y^{(2)})$ en un sistema de coordenadas cartesianas se define como:

$$d_1(x, y) = |x^{(1)} - y^{(1)}| + |x^{(2)} - y^{(2)}| \quad (3.5)$$

La distancia euclideana entre puntos $x = (x^{(1)}, x^{(2)})$ y $y = (y^{(1)}, y^{(2)})$ en un sistema de coordenadas cartesianas se define como:

$$d_2(x, y) = \sqrt{(x^{(1)} - y^{(1)})^2 + (x^{(2)} - y^{(2)})^2} \quad (3.6)$$

A menos que el área de estudio tenga una red de calles que siga una cuadrícula uniforme, medir distancias horizontal y verticalmente puede conducir a una sobreestimación de las distancias de viaje. Además, cuanto más difiere el diseño de una orientación norte-sur y este-oeste, mayor es la distorsión. Dado que muchas áreas urbanas no tienen un trazado de calles de cuadrícula uniforme, el método conducirá

necesariamente a una sobreestimación de las distancias de viaje en lugares donde hay calles diagonales o irregulares.

Adicionalmente, la métrica empleada para calcular distancias debería adaptarse según la estructura de la red vial. Es importante considerar que el entorno urbano en las ciudades de EEUU suele diferir significativamente de las antiguas ciudades europeas en aspectos como la red de calles y la densidad. Esta variabilidad puede influir en una distribución distinta tanto de objetivos como de delitos (Brantingham y Brantingham, 1990). Asimismo, podría dar lugar a diferentes comportamientos microespaciales por parte de los delincuentes (Alston, 1994).

7. Rossmo (2000) midió la precisión del sistema utilizando un porcentaje de puntuación de acierto como indicador. La puntuación de aciertos de CGT representa el valor de la densidad en la celda de la cuadrícula donde realmente reside la casa del delincuente. Como método, el algoritmo CGT de Rigel parece contar las densidades en los centroides de las celdas de una cuadrícula de 40.000 "píxeles" (Rossmo, 2000; 2005), con valores de densidad que representan la probabilidad de que el delincuente resida en una cierta celda de la cuadrícula. Esta cuadrícula tiene grupos de celdas de diferentes niveles de densidad, siendo más probable que las celdas de mayor densidad contengan un punto espacial focal para un delincuente, como el hogar del delincuente.

Aunque esta función de decaimiento a menudo se denomina distribución de probabilidad, esto no es técnicamente cierto ya que no hay ningún requisito para que la superficie se integre a la unidad (ni, en criminología, ninguna necesidad de que lo haga, ya que el análisis se usa para producir puntuaciones clasificadas en lugar de

probabilidades). Por lo tanto, en el método tradicional, la función de decaimiento se describe mejor como una superficie de prioridad de búsqueda sujeta a la restricción más general de que los puntos altos en la superficie representan áreas de alta prioridad. Esta medida de prioridad se modela como una cantidad aditiva, lo que significa que la información de varias observaciones se puede combinar sumando las superficies independientes. El resultado final de este proceso de suma es una superficie única que representa nuestro conocimiento integrado de la ubicación de la fuente, que se conoce como superficie de peligro (Rossmo, 2000).

De hecho, el término probabilidad no es el término correcto para denotar el resultado que nos devuelve la fórmula (es un valor relativo). Dado que la probabilidad de interacción entre cualquier celda de la cuadrícula, i , y cualquier incidente, j , no puede ser mayor que 1, la superficie en realidad indica el producto de las probabilidades individuales de que el delincuente use esa ubicación como base de operaciones. Para ser una función de probabilidad real, tendría que reajustarse para que la suma de las celdas de la cuadrícula fuera igual a 1. En efecto, este último calcula, para cada zona del mapa, un valor determinado. Y lo que vamos a hacer es solo relativizar los diferentes valores entre ellos. Entonces, si por ejemplo el valor más alto corresponde a 2000, y el más alto pequeño a 1000, definiremos que el primero es igual al 100% y el segundo al 0%. Por lo tanto, la zona de valor 1500 valdrá el 50%.

El resultado es un modelo de superficie que indica la probabilidad de que el delincuente resida en ese lugar en comparación con otras áreas del mapa (Figura 3-4). Lo describe como una superficie de probabilidad, pero en realidad es una superficie de densidad.

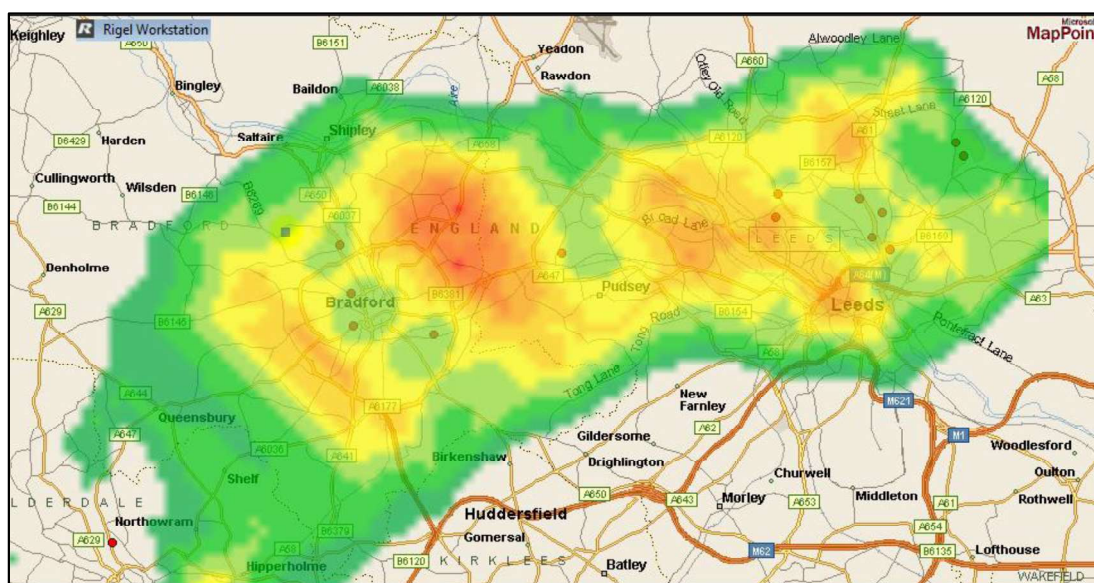


Figura 3-4: Modelo de superficie que indica la probabilidad de que el delincuente resida en ese lugar. Modelo realizado con Geographic Profiling ECRi online Rigel Software Server (Caso Peter Sutcliffe).

8. El porcentaje de puntuación de acierto es el porcentaje de celdas en el área de caza con un valor de densidad igual o superior al valor que tiene la celda de cuadrícula que contiene la residencia del delincuente. Un área de caza se define como la zona rectangular que contiene todos los lugares del delito (en una serie). Rigel usa un rectángulo delimitador mínimo para su área de actuación, con una pequeña adición de

un área para efectos de borde (calcula los límites del área de caza sumando la mitad de las distancias medias x e y entre los puntos de los sitios del crimen más al este y oeste, y al norte y al sur, respectivamente (Boots y Getis, 1988; Gatrell et al., 1996).

Hay varios problemas con esta medida de precisión. En primer lugar, dado que cada serie de delitos define su propia zona de caza, los resultados de las diferentes series de delitos pueden difícilmente ser comparables. Es decir, para un asesino en serie que comete delitos en todo EEUU, el área de caza es más grande que para un delincuente local (robos) que solo está activo en un barrio. En el primer caso, incluso si el método pudiera proporcionar un porcentaje de puntuación de acierto mínimo, el 1% del área de caza aún resultaría fácilmente en un área de búsqueda extremadamente grande para la policía. Se necesitaría alguna indicación del tamaño de la población objetivo en el área de búsqueda resultante para dar una indicación del beneficio de usar el método.

9. Un tercer problema está en la función de disminución de la distancia. El uso de un término de distancia inversa tiene problemas ya que la distancia entre la ubicación de la celda de la cuadrícula, i , y la ubicación del incidente, j , disminuye. Para algunos tipos de delitos, habrá poca o ninguna zona de amortiguación alrededor de la base de operaciones del delincuente (por ejemplo, agresiones sexuales cometidas por conocidos). En consecuencia, el radio de la zona de amortiguamiento, B , se acercaría a 0. Sin embargo, esto haría que el modelo se volviera inestable ya que el término de la distancia inversa se acercaría al infinito.

Este comportamiento de función delta es preocupante, ya que esencialmente establece que el delincuente vive justo al lado de la escena del crimen o en el límite

definido por Rossmo. Por lo tanto, el valor B se vuelve excepcionalmente importante y necesita su propia heurística para garantizar su precisión. Una elección no óptima de B puede resultar en zonas de búsqueda altamente inestables que varían cuando B se modifica levemente (Morrow, 2010).

10. El uso de una función matemática para describir la disminución de la distancia, aunque es fácil de definir, probablemente simplifica demasiado el comportamiento real del viaje. Supone que el viaje es igualmente probable en cada dirección, que la distancia de viaje es uniformemente fácil (o difícil) en cada dirección y que, de manera similar, las oportunidades se distribuyen uniformemente. Para la mayoría de las áreas urbanas, estas condiciones no serían ciertas. Una función matemática no considera esta estructura, sino que asume que todos los delincuentes muestran la misma función de deterioro de la distancia, independientemente de dónde vivan o qué tipo de delito cometan.

La crítica mencionada, evidentemente, aplicaría a todas las formulaciones matemáticas relacionadas con la distancia de desplazamiento. Sin embargo, existen ajustes que se pueden implementar para rectificarlo. Por ejemplo, en modelos de demanda de desplazamiento urbano, la distribución de los trayectos entre distintos puntos se calcula a través de un modelo gravitacional. Sin embargo, los viajes asignados a esta distribución están restringidos: primero, por el volumen total de trayectos en la zona (calculado de manera independiente); segundo, por el medio de transporte utilizado; y tercero, por la configuración de las rutas en las que, en última instancia, se distribuyen los trayectos (Field y MacGregor, 1987; Krueckeberg y Silvers, 1974; Stopher y Meyburg, 1975).

11. La calibración constante con bases de datos reconocidas asegura que los coeficientes y exponentes concuerden lo más precisamente posible con datos actualizados. Estos tipos de ajustes son esenciales para que el modelo de distribución de viajes sugerido por Rossmo se adapte a un enfoque real.

Otra de las debilidades encontradas en la herramienta es la fundamentada por van Der Kemp (2014) al indicar que calibrar una función de disminución de la distancia implica que, con base en los datos empíricos de las distancias de viaje de los infractores anteriores, sería posible combinar la determinación del punto de distancia mínima con una distribución de probabilidad de acuerdo con una función de disminución de la distancia para llegar a una predicción de punto ponderado. Se estima que los parámetros no publicados de la función de disminución de la distancia se adaptan mejor a esas distancias de viaje. Utilizando una función de disminución de la distancia calibrada, se puede estimar una función que refleje mejor el comportamiento de viaje del tipo de delincuente que se va a perfilar (Canter y Hammond, 2006a). Obviamente, el éxito de la calibración depende fundamentalmente de la suposición de que el infractor que se va a perfilar es "igual" a los infractores utilizados para la calibración. Los programas Dragnet (Canter, 1995) y CrimeStat (Levine, 2015) ofrecen la posibilidad de calibrar las funciones de disminución de la distancia, posibilidad no desarrollada por la herramienta Rigel.

12. Las oportunidades para cometer delitos: el atractivo de ubicaciones, nunca se miden. Es decir, no se enumeran las oportunidades que existirían para un delincuente ni se intenta medir la fuerza de esta atracción. En cambio, el área de búsqueda se infiere estrictamente de la distribución de incidentes. Debido a que se esperaría que la

distribución de las oportunidades para los delincuentes varíe de un lugar a otro, el modelo deberá volver a calibrarse en cada ubicación.

13. Finalmente, Rossmo también argumenta que se requieren un mínimo de 5 localizaciones (sin un estudio que respalde de manera confiable esta afirmación) para la creación de un perfil geográfico, lo que limita la utilidad del método, pero esa cifra parece basarse más en las necesidades de los investigadores policiales que en criterios teóricos o prácticos (Snook, Taylor, et al., 2005), incluso con menos delitos, la elaboración de perfiles geográficos puede resultar útil (Canter, 2005; Snook, Taylor, et al., 2005).

El enfoque, y el sistema de Rigel basado en él, no han sido apoyados por ninguna prueba empírica científicamente válida (Levine, 2004; Snook, Zito, et al., 2005). La propuesta de Rossmo de usar el sistema específicamente para investigaciones de homicidios en serie es discutible. Como se ha observado, la actividad geográfica de los asesinos en serie puede abarcar vastas distancias, lo que sugiere que este podría ser un tipo de delito espacialmente atípico, haciendo que la predicción de la ubicación de su residencia sea particularmente complicada.

Otra limitación de los sistemas de apoyo a la elaboración de perfiles geográficos es su falta de inclusión de la información sobre las acciones de los delincuentes durante la comisión de sus delitos. Estos sistemas informatizados no se integran, por lo general, con datos relevantes sobre un gran número de delincuentes presentes en las bases de datos policiales. La combinación de esta información añadiría, sin duda, un valor investigativo superior al análisis meramente geográfico de la delincuencia. En el caso de Rigel se pueden introducir sospechosos, series identificadas y delitos, siendo una fortaleza para el modelo.

Otra de las fortalezas que dispone el software es la elección de escenarios para su análisis posterior, Rossmo et al. (2005), indica que los valores atípicos anómalos son un problema para la elaboración de perfiles geográficos, ya que tienden a tener un efecto desproporcionado en el perfil. Se puede tolerar una pequeña cantidad, pero es mejor identificar y eliminar tales valores atípicos, ya que la experiencia práctica en un gran número de casos ha demostrado que la mayoría de las veces son erróneos o representan un comportamiento genuinamente anómalo (por ejemplo, un viaje inusual fuera de espacio de actividad normal por parte del sospechoso).

Cuando el infractor repite sus elecciones o acciones que constituyen una coincidencia, usualmente es fácil identificar el patrón, y determinar qué factores son importantes para él y predecir cómo decidirá en el futuro. Sin embargo, a veces el infractor no repite sus elecciones. Algunos pueden evitar patrones de manera intencionada, cambiando las preferencias de sus objetivos. No obstante, eso también es un patrón. Si el infractor cambia radicalmente el tipo de objetivo a los que ataca, podemos excluir de nuestra predicción la clase de lugares que atacó antes (Paulsen et al., 2009). Los nuevos escenarios creados por el delincuente pueden no ajustarse al patrón normal visto en la serie. Podrían estar demasiado lejos de los otros delitos en el espacio o el tiempo, o podrían representar algún otro tipo de comportamiento anómalo, es la razón por la que se deben excluir para la realización del perfil geográfico.

El *Rigel Expert System* (Rossmo, 1997c) integra un conjunto estándar de criterios y sugiere la exclusión de valores atípicos y de lugares interdependientes.

El conjunto completo de delitos que conforman un caso, se denomina escenario del caso base y la razón principal para desarrollar un escenario en su lugar de utilizar todos los delitos es que algunos delitos deben ser excluidos porque no se ajustan al modelo o violan un supuesto, estos valores atípicos son delitos que no se ajustan a lo normal patrón visto en la serie. Ellos también

podrían ser distante de los otros crímenes en el espacio o el tiempo (periodo de enfriamiento), o podrían representar algún otro tipo de anomalía comportamiento (por ejemplo, la única vez que el delincuente aparentemente usó un automóvil en lugar de ir a pie).

En la selección de escenarios, se aplica un conjunto de reglas basadas en el modelo subyacente de viaje del delincuente y selección de la escena del crimen. El escenario debe incluir solo delitos que representen viajes independientes a la escena del delito, desde la base de investigación común. Algunas de las reglas de tiempo y distancia son verificadas automáticamente por el software, mientras que otras requieren el conocimiento del analista.

Morrow (2010), propone incorporar la media espacial para suavizar el efecto de los valores atípicos al dar un impulso de probabilidad a las regiones cercanas al centro de masa, lo que significa que es poco probable que los valores atípicos aparezcan como zonas calientes. Por lo tanto, las áreas cercanas a la media espacial tienen más probabilidades de aparecer como zonas calientes, mientras que las áreas más alejadas de la media espacial tienen menos probabilidades de ser vistas como zonas calientes. Esto asegura que la idea intuitiva de centrografía se incorpore en el modelo y también proporciona un área general para buscar (véase capítulo 11).

En el ámbito del software especializado en perfil geográfico, Rigel se posiciona como la herramienta comercial de perfilado geográfico única en el mercado. La capacitación no solo es esencial para manejar eficazmente el software Rigel, sino que también es vital para comprender a fondo la teoría y práctica detrás del perfil geográfico.

Se han realizado diversas propuestas de modificación del método, Butkovic et al. (2019) diseñaron el software “GeoCrime”, con la opción de modificar diversos parámetros de la ecuación. Por su parte, Papini y Santosuosso (2017), modificaron el método aplicando un peso a cada punto del mapa donde se reportaron casos de cólera; este peso era proporcional al número de casos en

un lugar determinado. Salafranca y Maldonado (2018) sugieren realizar una calibración en el parámetro B (zona de seguridad) de la ecuación CGT para identificar el domicilio del incendiario, según sea éste de tipo serial, en masa o espontáneo. Stevenson (2015) propone una variante, introducida primero por Le Comber et al. (2006), que utiliza distancias euclidianas en lugar de Manhattan.

Dentro de las estrategias de perfilado geográfico, el software RIGEL permite analizar las siguientes medidas de tendencia central: el centro medio, centro mediano, centro de distancia mínima y el algoritmo CGT (*Criminal Geographic Targeting*).

Dragnet

El profesor David Canter del Centro de Psicología Investigativa de la Universidad de Liverpool (Reino Unido) desarrolló el software Dragnet (Canter, 1995) a mediados de la década de 1990 como una herramienta de investigación para analizar patrones espaciales en delitos en serie.

La herramienta Dragnet emplea la función exponencial negativa, como se muestra en la siguiente ecuación:

$$Y = \alpha e^{-\beta \frac{D_{ij}}{P}} \quad (3.7)$$

donde Y es la probabilidad de que un delincuente viaje una cierta distancia para cometer un delito, D_{ij} es la distancia (desde la ubicación de la base de operaciones hasta el lugar del incidente), α es una constante arbitraria, β es el coeficiente de la distancia, P es una constante de normalización, y e es la base del logaritmo natural. El modelo es similar a la ecuación 3.1 excepto que, como Rossmo, no incluye el atractivo de la ubicación (Levine, 2013).

Los archivos de función que Dragnet usa para caracterizar la función de decaimiento, se componen de 20 valores (valores del eje x) que representan la forma y la forma de la función. Por ejemplo; los 20 valores utilizados para caracterizar una función exponencial negativa básica

$$Y = \alpha e^{-Bx} \quad (3.8)$$

son los siguientes:

[1]0.5 [2]0.441248 [3]0.3894 [4]0.343645 [5]0.303265 [6]0.267631 [7]0.236183 [8]0.208431
 [9]0.18394 [10]0.162326 [11]0.143252 [12]0.12642 [13]0.111565 [14]0.098456 [15]0.086887
 [16]0.076677 [17]0.067668 [18] 0.059716 [19]0.0527 [20]0.046507

Todos estos son puntos que representan una función exponencial con un valor β de 1.0:

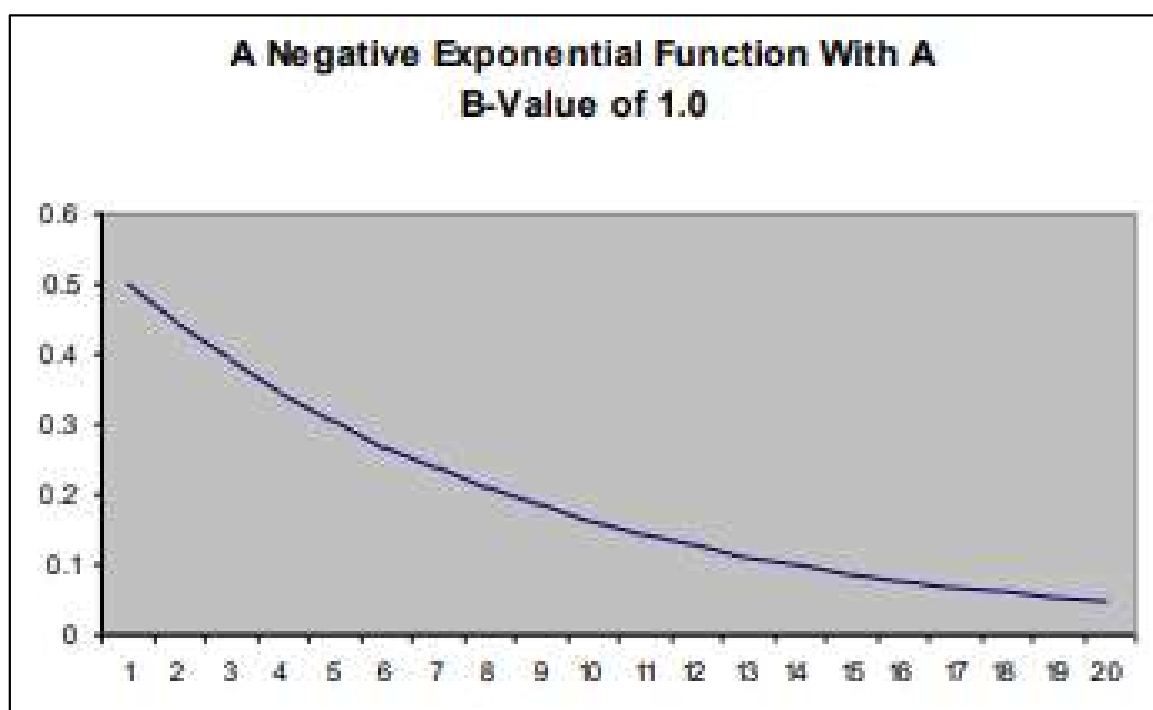


Figura 3-5. Función Negative Exponencial. Tomado del *Manual Dragnet A user Guide*, (p.10) Canter and Hammond, (2006).

Basándose en la premisa de que la mayoría de los delitos se ejecutan cerca de la base de operaciones del infractor, Canter et al. (2000) propusieron una metodología de cinco etapas para diseñar una estrategia de búsqueda (Levine, 2013):

1. El área de estudio está definida por un rectángulo que es un 20% más grande en área que la definida por los puntos X / Y mínimo y máximo. Se impone una estructura de celda de cuadrícula de 13.300 celdas sobre el rectángulo. Cada celda de la cuadrícula es una referencia de la ubicación, i (figura 3-6).




Figura 3-6: Modelo de probabilidad Dragnet (Caso Peter Sutcliffe) (Métrica euclideana).

2. Se selecciona un coeficiente de decaimiento. En la ecuación (3.5), este sería el coeficiente, β , para el término de distancia, D_{ij} , los cuales son exponentes de e .

A diferencia de Rossmo, Canter utiliza una serie de coeficientes de desintegración de 0.1 a 10 para estimar la sensibilidad del modelo. La ecuación indica la probabilidad con la que es probable que cualquier lugar sea la base de operaciones del delincuente en función de un incidente.

3. Debido a que los diferentes delincuentes tienen diferentes áreas de búsqueda, las distancias medidas para cada celda se dividen por un coeficiente de normalización, P , que ajusta todos los delitos a un rango comparable. Canter utiliza dos tipos diferentes de funciones de normalización (Canter et al., 2000);

1) Distancia media entre puntos entre todos los delitos (en adelante MID). Da la misma importancia a todas las distancias. Por consiguiente, se elaboró un índice que proporciona una indicación numérica de la distribución media de los delitos en torno a un eje ficticio. Este eje se determinó calculando la regresión lineal de las coordenadas del lugar del delito dentro de una distribución de delitos.




Figura 3-7: Visualización Dragnet. Normalización MID. Caso Instrumental Peter Sutcliffe.

2) El *QRange*, que es un índice que tiene en cuenta la asimetría en la orientación de las incidencias. Se basa en las propuestas de Brantingham y Brantingham (1981) y Rengert y Wasilchick (1985) en donde las vías de comunicación utilizadas por el delincuente pueden ser significativas para la localización de sus delitos. Por lo tanto, es posible que exista una estructura lineal dominante en la distribución de los delitos. El *QRange* se define como la distancia

perpendicular media de todos los puntos de infracción al eje de regresión inherente a una distribución de infracciones. Cuanto más cerca estén los delitos del eje de regresión, menor será el valor de *QRange*.

4. Para cada celda de referencia, *i*, la distancia entre cada celda de la cuadrícula y cada ubicación del incidente se evalúa con la función y las probabilidades estandarizadas se suman para producir una estimación del potencial de ubicación.




Figura 3-8: Visualización Dragnet.
Normalización Q-Range.
Caso Instrumental Peter Sutcliffe.

5. Un índice de coste de búsqueda se define por la proporción del área de estudio que debe buscarse para encontrar al delincuente. Al calibrar el modelo con casos conocidos, se obtiene una estimación de la eficiencia de búsqueda (véase figura 3-10).




Figura 3-9 Visualización Dragnet. Resultado Coste Búsqueda. Caso Instrumental Peter Sutcliffe. (Métrica Manhattan)




Figura 3-10: Ampliación resultado Coste Búsqueda. Caso Instrumental Peter Sutcliffe.

La función predeterminada es una función exponencial negativa, sin embargo, es posible emplear un conjunto de 20 valores de x para representar diversas funciones, como la logarítmica, cuadrática o una función lineal simple para control.

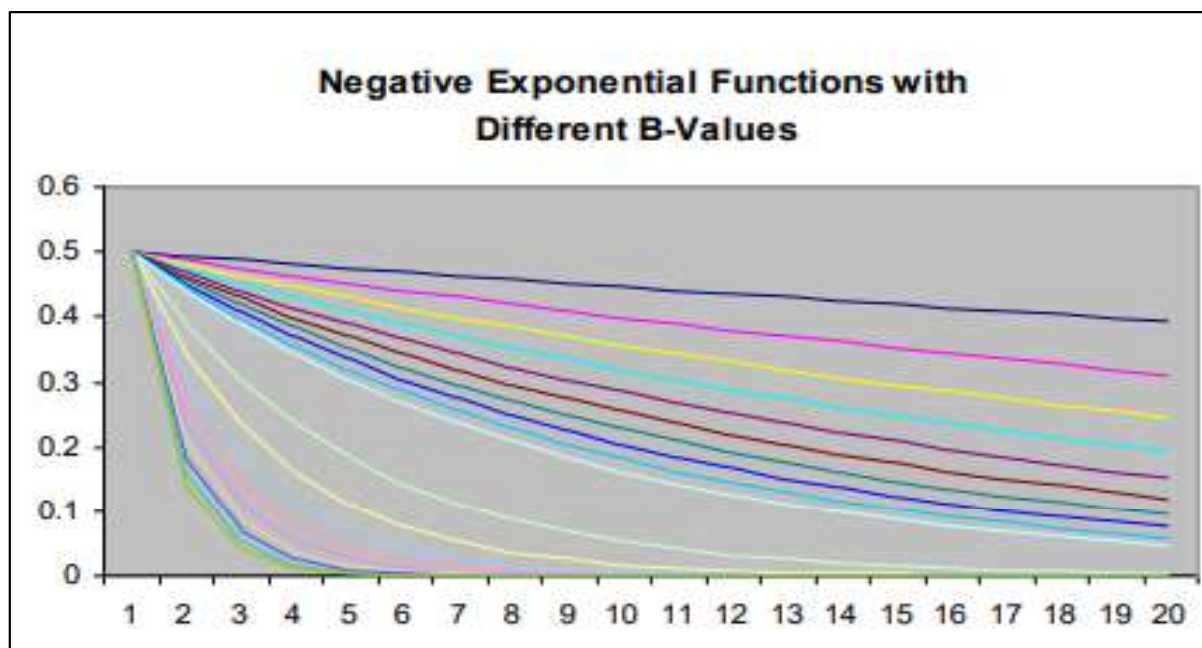


Figura 3-11: Función Negativa Exponencial con diferentes valores B. Adaptado del Manual Dragnet A user Guide (p.11) Canter and Hammon, (2006)

Es notable mencionar que las funciones exponenciales pueden adaptarse utilizando una diversidad de valores β , lo que permite representar múltiples configuraciones de la función; logarítmica, cuadrático, lineal simple, distribución bimodal, (si se cree que un delincuente está operando dentro de dos diferentes rangos) y puede incluir características como una zona de amortiguación. Canter et al. (2000) añadieron capacidades adicionales al algoritmo para modelar la presencia o ausencia de una zona de amortiguación. Para representar la zona, se utilizan áreas con valores B constantes de 0 (zona de amortiguación) o 1 (sin zona de amortiguación) situadas antes de la función exponencial. Por ejemplo, se utilizan "etapas" para modelar la presencia de una zona de amortiguación, áreas alrededor del refugio donde la actividad delictiva es inexistente (valor $B = 0$); y las "mesetas" representan la ausencia de una zona de amortiguación (valor $B = 1$),

un área alrededor del refugio donde es más probable que ocurra actividad delictiva. Después de una cierta distancia, hasta un máximo de 4 unidades, la curva de decaimiento de distancia continúa, representada por un conjunto de ecuaciones exponenciales negativas.

Con 285 formas de funciones y 2 parámetros de normalización, resultando 570 funciones exponenciales negativas diferentes, Canter et al. (2000) lograron áreas de búsqueda promedio de 19% (MID) y 11% (*QRange*), al considerar los resultados recibidos, utilizando funciones óptimas. Las áreas de búsqueda se calcularon como un área rectangular definida por la ubicación de los delitos en la serie ampliada en un 20%. Las funciones óptimas se seleccionaron después de que se hicieron las predicciones.

Fortalezas y debilidades modelo

1. El modelo proporciona una estrategia de búsqueda para las organizaciones policiales. Al examinar qué tipo de función se adapta mejor a un determinado tipo de delito, la policía puede orientar sus esfuerzos de búsqueda de manera más eficiente. El modelo es relativamente fácil de implementar y práctico. Se pueden agregar modificaciones adicionales a las funciones para hacerlas más flexibles (Canter et al., 2000).
2. La formulación matemática es estable. A diferencia de la función de distancia inversa en el modelo de Rossmo, no tiene problemas asociados con distancias cercanas a 0. Además, el modelo proporciona una estrategia de búsqueda para identificar a un delincuente.

3. Carece de base teórica. La investigación de Canter ha proporcionado mucho en términos de comprensión de los espacios de actividad de los delincuentes en serie (Canter y Larkin, 1993; Canter y Gregory, 1994; Canter, 1994; Hodge y Canter, 1998). Sin embargo, el modelo empírico utilizado es estrictamente pragmático. En segundo lugar, matemáticamente impone la función exponencial negativa sin considerar otros modelos de decaimiento de distancia.
4. Dragnet asume que todos los infractores siguen una función exponencial negativa, pero la escala se puede ajustar de modo que, en teoría, se puede explorar cualquier función. Sin embargo, el valor predeterminado es una exponencial negativa que se ha utilizado en muchos estudios de comportamiento de viaje (Foot, 1981; Bossard, 1993), pero no siempre produce el mejor ajuste. Si bien el modelo se puede adaptar para que sea más flexible mediante diferentes exponentes e incluyendo pasos y mesetas, por ejemplo, todavía está vinculado a la forma exponencial negativa. Por lo tanto, el modelo puede funcionar en algunas ubicaciones, pero puede fallar en otras; un usuario no puede ajustar fácilmente el modelo para que se ajuste a nuevos datos. El programa ofrece flexibilidad porque las funciones de disminución de la distancia se pueden calibrar en función de los problemas resueltos (Kemp, 2014).
5. El coeficiente de la exponencial negativa, α , se define arbitrariamente. En la Dragnet programa, generalmente se establece en 0.5. Aunque garantiza que el resultado nunca sobrepase el valor de 1.0 para cualquier incidente, hay una restricción en la suma del potencial de ubicación. Dicho potencial total depende del número de incidentes, lo que significa que será más elevado a medida que haya más

incidentes. Sería preferible que el coeficiente se hubiera ajustado utilizando una muestra previamente conocida (Levine et al., 2013).

6. También similar al modelo de Rossmo, las oportunidades (o atractores) delictivas nunca se miden, sino que se infieren del patrón de incidentes delictivos. Como herramienta pragmática para informar una búsqueda policial, se podría argumentar que esto no es importante. Sin embargo, en una ubicación diferente, el coeficiente de distancia puede diferir al igual que el índice de coste de búsqueda, debería volver a calibrarse cada vez.
7. Las áreas de búsqueda se calcularon como un área rectangular definida por la ubicación de los delitos en la serie ampliada en un 20%. Sobre él, como con Rossmo, se superpone una cuadrícula de celdas. Esa cuadrícula contiene 13.300 celdas, se desconoce la motivación de utilizar una cantidad determinada de celdas (van Der Kemp, 2014).
8. Dragnet no está actualmente vinculado a un SIG para permitir la superposición de la salida y el módulo de informes no está activado.
9. Dado que la amplia distribución de Dragnet no ha sido una prioridad para Dr. Canter, el software no está disponible actualmente para descargar desde una WEB. Los investigadores interesados en obtener el software deben solicitarlo.

Dragnet permite que se utilice cualquier tipo de función para modelar la distancia que viajan los delincuentes para cometer delitos, aunque Canter et al (2000) informan que una función de decaimiento negativa simple sin zonas de amortiguamiento fue la más efectiva para los conjuntos de datos particulares que probaron.

En realidad, Dragnet utiliza una función exponencial negativa que se asemeja a la función lineal de disminución de la distancia, pero se diferencia de ella en el sentido de que la probabilidad de que un delincuente viva en una ubicación particular disminuye exponencialmente, en lugar de hacerlo linealmente. Además, el programa de Canter no incluye una zona de amortiguamiento (van Der Kemp y van Koppen, 2007).

Dentro de las estrategias de perfilado geográfico, el software Dragnet permite analizar las siguientes medidas: Centroide, M.I.D. (Media de las distancias entre los puntos), Q-Range, y la función negativa exponencial.

CrimeStat

El Dr. Ned Levine, en colaboración con otros investigadores y analistas de delitos policiales, desarrolló CrimeStat (Levine, 2015) con fondos del Instituto Nacional de Justicia. Desde la primera versión en 1999, CrimeStat se ha actualizado cinco veces (Versión 1.1 en 2000, Versión 2.0 en 2002, Versión 3.0 en 2004, Versión 4.0 en 2013 y Versión 4.02 en 2019). El propósito de CrimeStat IV es proporcionar una variedad de herramientas para el análisis espacial de incidentes delictivos u otras ubicaciones de puntos.

CrimeStat ofrece una funcionalidad específica para la elaboración de perfiles geográficos, denominada "*journey to crime estimation*". Esta herramienta busca establecer una distinción clara entre esta función y el concepto general de perfiles geográficos. Según Levine, la elaboración de perfiles geográficos abarca un espectro más amplio que simplemente analizar patrones predictivos. A pesar de este esfuerzo por diferenciar ambos conceptos, es común que muchos investigadores utilicen de manera indistinta el término "perfiles geográficos" para describir las herramientas de modelado predictivo como las que presenta CrimeStat (English, 2008).

CrimeStat, no se orienta esencialmente a la elaboración de perfiles geográficos, sino a una variedad de estadísticas espaciales para el análisis de la ubicación de los incidentes delictivos (Trotta, 2014).

El algoritmo del modelo *Journey to crime* (en adelante JTC), se basa en una combinación de teorías de ubicación, que intenta encontrar una ubicación óptima para cualquier distribución particular de actividades o población en una región, y modelos de demanda de viajes desarrollados para planificadores de transporte, ampliando la capacidad de modelado en relación con el algoritmo de Rossmo (Levine, 2002).

En los modelos de JTC, el comportamiento de viaje delictivo se observa midiendo la distancia entre el lugar conocido del delito y la residencia conocida del delincuente. El comportamiento se cuantifica trazando las distancias estadísticamente agregadas contra el número de delitos cometidos para ilustrar el porcentaje de delitos para una unidad de distancia determinada (Kent, 2006).

La estimación del viaje al delito es un método para identificar una base probable dada la distribución de los sitios del delito y las suposiciones sobre el comportamiento de los viajes (Levine, 2010).

Es un término acuñado por primera vez por Philips (1980), en relación al estudio del comportamiento de viaje entre la residencia de un delincuente hacia y desde la escena del delito. El enfoque del viaje al delito es un precursor de las técnicas de elaboración de perfiles geográficos y se ha utilizado durante años para localizar el origen probable de un delincuente en serie en función de las propiedades asociadas con la distribución de los incidentes delictivos (Levine, 2007).

Ned Levine ha defendido un enfoque estadístico para la predicción de la ubicación del domicilio y, en particular, sugiere también un enfoque empírico para la formación de modelos de distancias entre el domicilio y la ubicación del delito (Levine, 2004). Al ser pionero en el enfoque para predecir la ubicación del hogar de un delincuente a partir de las ubicaciones espaciales de las ubicaciones del delito con un modelo estimado de densidad de kernel, derivado de forma empírica, los resultados de Ned Levine con respecto a la precisión del método, obtenidos mediante el software CrimeStat (Levine, 2015), fueron mixtos y muy variados (Levine, 2004). Aunque su muestra era pequeña (50 series del condado de Baltimore, incluidos diferentes tipos de delitos, de los cuales 27 fueron series de hurtos), su conclusión fue que los métodos simples generalmente darán resultados tan buenos o tan malos como los más complejos (Laukkanen, 2007).

CrimeStat ofrece un amplio catálogo de herramientas para la elaboración de perfiles geográficos. Permite diversas métricas, incluyendo la media y el centro de distancia mínima, entre otras características. Además, ofrece la flexibilidad de utilizar diferentes funciones de decaimiento de distancia para construir un perfil geográfico más detallado y ajustado a las necesidades de la investigación.

Este modelo se desarrolla en tres etapas esenciales:

1. Se superpone una cuadrícula en la parte superior del área de estudio. La cuadrícula representa toda el área de estudio (área de actuación). No existe un área de estudio óptima ni predefinida.
2. Se aplica una función de disminución de distancia a cada par de incidentes de celda de cuadrícula y suma los valores de todos los incidentes. El usuario tiene la opción de modelar

la distancia de viaje mediante una función matemática o una función derivada empíricamente.

3. El resultado de la función de disminución de la distancia para cada par de incidentes de celda de cuadrícula se suma a todos los incidentes para producir una estimación de probabilidad (o densidad) para cada celda de cuadrícula.

En ambos casos, el programa genera los dos resultados (Figura 3-12):

- 1) La celda de la cuadrícula que tiene la estimación de probabilidad máxima (*Peak likelihood location*);
- 2) La estimación de probabilidad para cada celda (puntaje z)

Santtila et al. (2003) afirmaron que el software CrimeStat realiza predicciones sobre la probabilidad de que diferentes ubicaciones contengan la base de operaciones del delincuente; estas predicciones se basan en una función de disminución de distancia seleccionada, aplicada a cada una de las ubicaciones del delito.

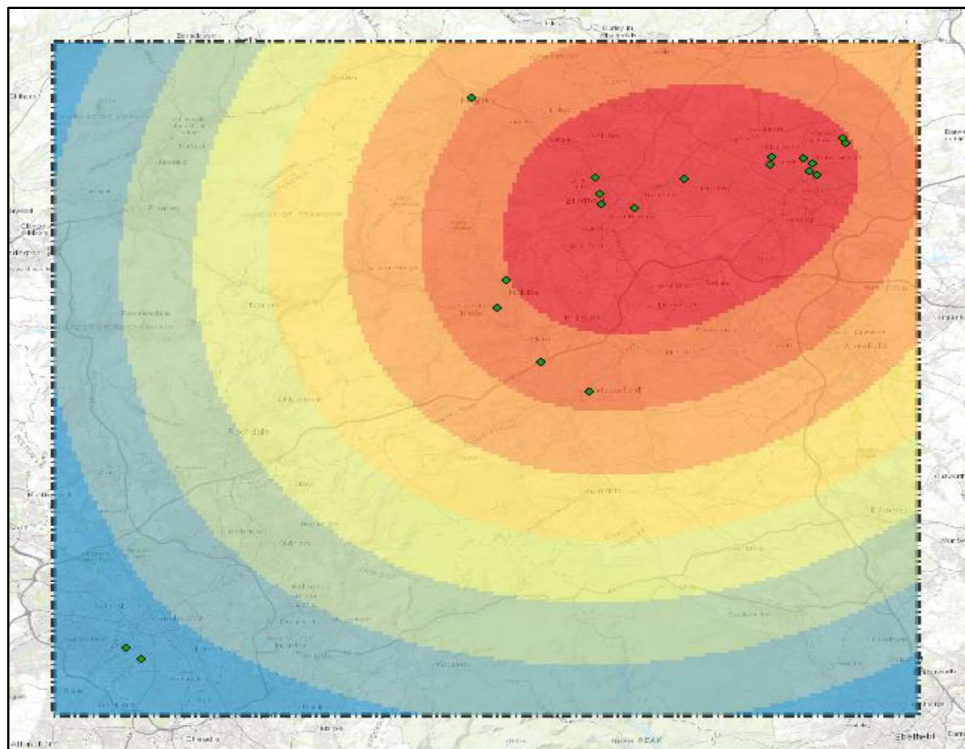


Figura 3-12. Modelo de probabilidad CrimeStat [Journey to Crime] Función Negative Exponential. Caso Instrumental Peter Sutcliffe.

Schmitz (2004) diferencia a CrimeStat del Rigel de Rossmo, ya que este último crea su propia zona de actuación. Por otro lado, CrimeStat utiliza una función de disminución de la distancia para cada par de incidentes de celda de la cuadrícula, y suma los valores de todos los incidentes para producir una estimación de probabilidad para cada píxel. Cuanto mayor sea el valor de píxel, mayor será la probabilidad de encontrar el punto de anclaje. Las funciones JTC presentan cinco funciones matemáticas estándar para modelar las distancias en los incidentes. vinculados, como se muestra en la figura 3-13. Estas funciones matemáticas se denominan funciones de probabilidad de distancia y son: lineal, exponencial negativa, normal, lognormal y exponencial negativa truncada (Levine, 2004).

La función lineal es la más sencilla de las cinco y se basa en el supuesto de que la probabilidad de un delito disminuye constantemente desde el punto de anclaje. Por su parte, la exponencial negativa presupone que el número de delitos disminuye con la distancia desde el punto base, pero con un descenso exponencial en lugar de constante. La función normal supone que el infractor establece una zona de seguridad y comete sus delitos lejos del punto de anclaje, alcanzando un máximo a cierta distancia para luego disminuir; en esta distribución, las tasas de aumento y disminución son equivalentes.

Crimestat utiliza principalmente cinco funciones para caracterizar el decaimiento de la distancia. En lugar de usar parámetros preestablecidos para cada función, se puede optar por un conjunto de datos de calibración específico del área de estudio, definido a partir de los domicilios de los delincuentes y las ubicaciones de los delitos.

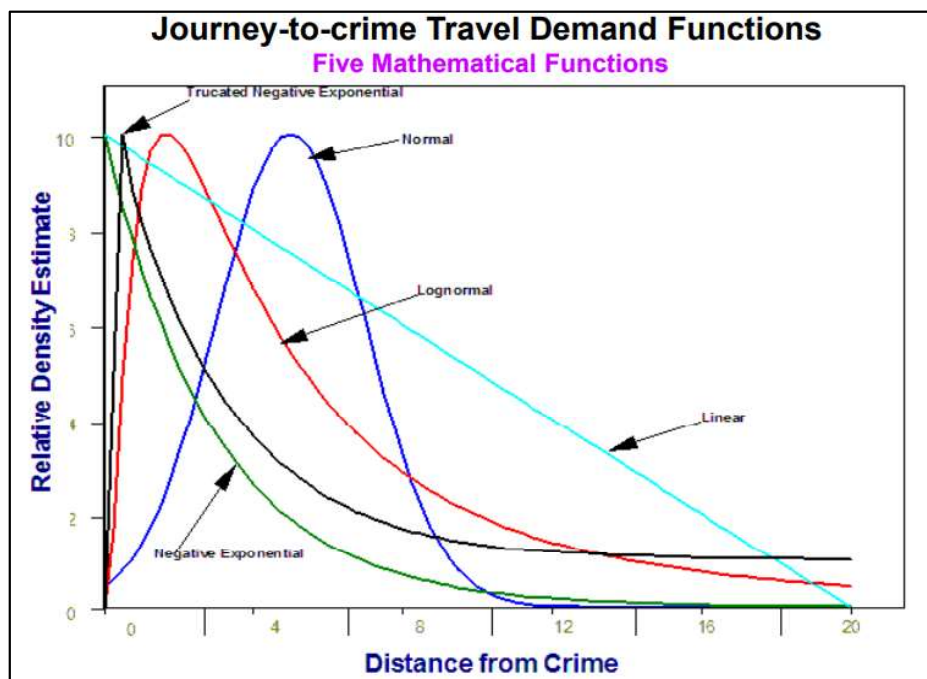


Figura 3-13: Funciones de decaimiento de distancia disponibles en CrimeStat. Adaptado de manual CrimeStat IV: *A Spatial Statistics Program for the Analysis of Crime Incident Locations*, Version 4.0 (p.810) por Levine y Associates, 2013.

Cabe destacar que, recientemente, las estrategias probabilísticas de viaje al delito se han extendido hacia el modelado bayesiano, como se ha observado en trabajos de (Bennell et al., 2009; Kent y Leitner, 2012; Mohler y Short, 2012; O’Leary, 2009)

La versión 3.0 de CrimeStat (Levine, 2004) introduce una significativa innovación: un modelo bayesiano para la elaboración de perfiles geográficos de delincuentes. Este modelo está diseñado para considerar la dirección de viaje habitualmente preferida por delincuentes de perfiles similares, una idea basada en los estudios de Koppen y Kemp (2010). Un enfoque bayesiano de la metodología de elaboración de perfiles geográficos implica actualizar las estimaciones de

probabilidad del viaje al delito con probabilidades basadas en la distribución de residencias de otros delincuentes que cometieron delitos en los mismos lugares (Levine y Block, 2011).

Levine (2005), sugiere que la integración del modelo bayesiano en la elaboración de perfiles geográficos conducirá a estimaciones más precisas sobre el origen de los delincuentes.

Su ventaja radica en la habilidad para generar estimaciones de probabilidad que se extienden más allá de la envolvente convexa. Al incorporar conocimientos previos sobre ubicaciones de origen potenciales, este modelo está preparado para superar ciertas limitaciones teóricas inherentes a los sistemas actuales, aportando una visión más rica y detallada en el proceso de perfilado.

Además, representa un paso adelante en la unión de la metodología con modelos de demanda de viajes. El resultado esperado es una notable mejora en términos de precisión y la creación de un modelo que no solo es más efectivo, sino también teóricamente más sólido y realista.

Rossmo (2022) plantea una perspectiva contraria sobre la aplicación de los modelos bayesianos en la elaboración de perfiles geográficos. Él argumenta que, aunque el enfoque bayesiano, que incorpora estimaciones empíricas de viajes hasta la escena del delito, busca enriquecer los modelos con datos históricos basados en áreas específicas, este método presenta limitaciones significativas.

El uso de información espacial sobre los desplazamientos anteriores de los delincuentes para calibrar análisis se basa en la suposición de que un delincuente desconocido probablemente reside en la misma área que los delincuentes anteriores que cometieron delitos en el mismo lugar. Sin embargo, Rossmo destaca que inferir la categorización individual de un sospechoso a partir de clasificaciones históricas por área conduce a una falacia ecológica. Además, señala que cuanto

mayor sea la congruencia supuesta entre delincuentes pasados y futuros sospechosos, más vacío se vuelve el análisis.

Rossmo enfatiza que los modelos bayesianos no son adecuados para informar la priorización de sospechosos, que es la función principal de la construcción de perfiles geográficos. En cambio, sugiere que su utilidad podría residir en estrategias policiales basadas en la priorización por área. Resalta que, sorprendentemente, esta limitación significativa de los modelos bayesianos en la generación de perfiles geográficos ha sido en gran medida ignorada en la literatura especializada.

Fortalezas y debilidades modelo

1. La flexibilidad del programa significa que el perfil geográfico no produce simplemente un perfil geográfico con solo presionar un botón, sino que deben tomarse decisiones bien consideradas para que se utilicen los parámetros (Koppen y Kemp, 2010).

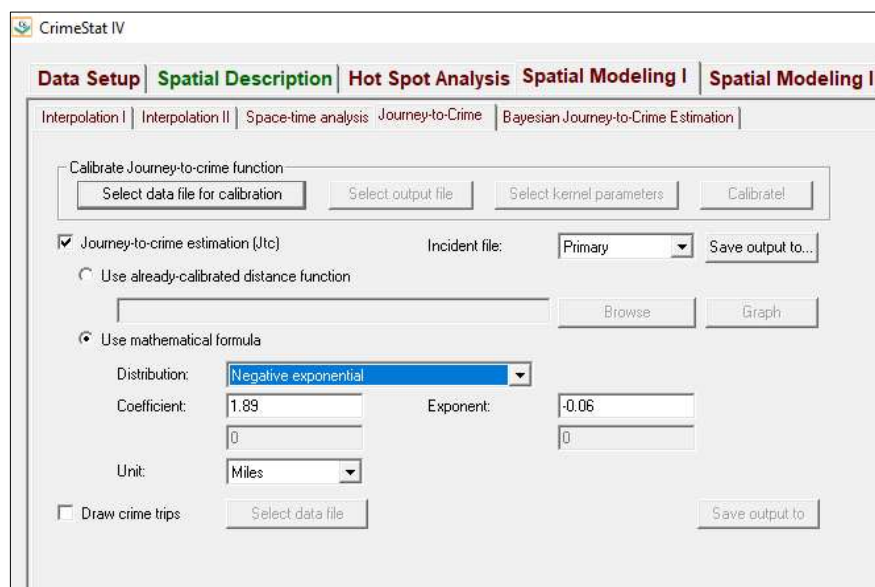


Figura 3-14: Configuración CrimeStat Journey to Crime

2. De hecho, Levine sostiene que los métodos son actualmente demasiado imprecisos para ser utilizados en investigaciones operativas de delitos sin mucha precaución. Los datos utilizados por Levine fueron bastante limitados para dar una indicación clara de la eficacia de los diferentes métodos. Sin embargo, este estudio constituye la única prueba de precisión publicada que utiliza un modelo empírico de distancias

entre el hogar y la ubicación del crimen. Pruebas separadas que utilizan modelos empíricos separados para diferentes tipos de delitos.

3. CrimeStat no está actualmente vinculado a un SIG para permitir la visualización. El resultado se entrega en formato ArcView [SHP], Atlas [GIS BNA], MapInfo [MIF] y Google [KML].
4. En relación con los supuestos teóricos y metodológicos fundamentales para la elaboración de perfiles geográficos, según Rossmo (2000), se considera esencial que el delincuente mantenga un único y estable punto de anclaje, así como un método de caza constante. Sin embargo, surge la pregunta: ¿cómo determinar estas características antes de capturar al delincuente? Reconstruir el comportamiento de un delincuente en serie tras su captura es una tarea, pero utilizar esta metodología de manera prospectiva con un delincuente aún libre presenta un desafío distinto. Una de las fortalezas destacadas en la herramienta más reciente de CrimeStat es la integración de una función de media móvil espacio-temporal. Esta característica permite formular hipótesis fundamentadas respecto a la estabilidad o variabilidad de los patrones de un delincuente. Esencialmente, esta herramienta calcula un centro medio basado en eventos delictivos secuenciales. Si se detecta que la media móvil se desplaza, en lugar de mantenerse dentro de una zona restringida, esto podría sugerir que el "punto de anclaje" del delincuente está en movimiento. Tal observación ofrece pistas cruciales sobre el comportamiento y los patrones de desplazamiento del delincuente, enriqueciendo el proceso de perfilado geográfico.

Predator

El Dr. Maurice Godwin desarrolló Predator (Godwin, 2001b), una aplicación de creación de perfiles geográficos que predice el domicilio de los delincuentes, supuestamente, utilizando el análisis del espacio más pequeño (en adelante SSA) para representar dónde reside un delincuente (Canter y Youngs, 2009). Sin embargo, se ha identificado muy poca información publicada sobre cómo Predator implementa los modelos. Según Godwin (2001), la aplicación parece explorar la distribución de los eventos delictivos desde posiciones angulares, modelando los desplazamientos delictivos mediante el empleo de dos teorías de ubicación y asignación que utilizan distancias medias entre puntos y en línea recta entre los sitios del delito. Con base en estos parámetros, parece que Predator intenta identificar el punto de distancia mínima entre las distribuciones de los sitios del delito medido por la SSA sin unidades (Godwin y Canter, 1997).

En su investigación Godwin (2001a), analizó los patrones de 107 asesinos en serie y descubrió que los lugares de los crímenes generalmente se sitúan dentro de un rango de 90 a 145 grados decimales en relación con la residencia del delincuente.

Como tal, esto puede respaldar significativamente cómo un criminólogo puede dirigir sus estrategias de investigación. Godwin señala además que, a diferencia de las aplicaciones de elaboración de perfiles geográficos contemporáneos, Predator no asume una zona de amortiguación pero la permitirá al analizar la interacción inicial entre el objetivo y el delincuente (Kent, 2003).

Fortalezas y debilidades modelo. Una de las fortalezas de la herramienta es que no asume que el área del crimen es solo circular, sino que mira las ubicaciones desde todas las posiciones angulares. La función calcula los dos lados de dos puntos usando la función Arctangent (Atn). Ni el modelo de Rossmo ni Dragnet consideran los ángulos de los crímenes.

1. Predator, no asume una "zona de amortiguación", pero, sin embargo, tiene en cuenta las zonas de amortiguación, especialmente al analizar los sitios de secuestro de las víctimas.
2. Usa las coordenadas Universal Traverse Mercator (en adelante UTM) más confiables para trazar las ubicaciones del crimen.
3. La herramienta SIG, Predator, no se ha comercializado ni compartido con nadie fuera de su campo (Rossmo, 2000).

Otras herramientas de Perfilado geográfico.

- GeoProfile. English (2008), desarrollo en la Escuela de Psicología de Chicago una herramienta de perfilado geográfico en un entorno web, utiliza una función de decaimiento de la distancia exponencial negativa y un área de referencia de 750*750 celdas (English, 2008).

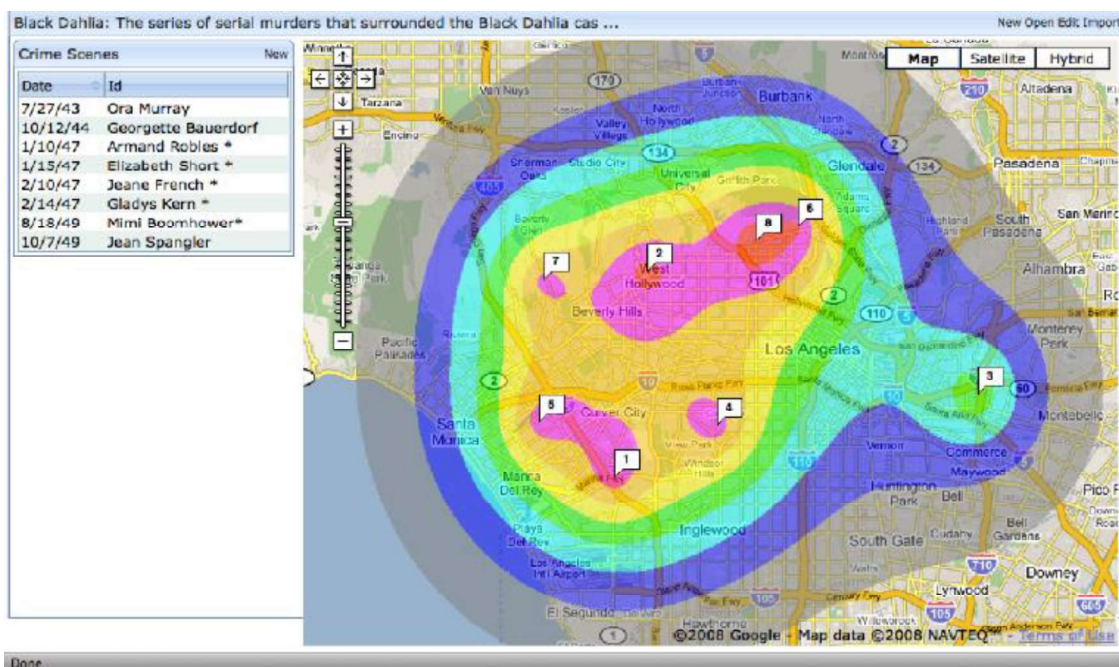


Figura 3-15. Pantalla de la interfaz de GeoProfile. Tomado de *Geoprofile: Developing and establishing the reliability of a new geographic profiling software system.* (p 48) English, 2008.

- (BAIR Analytics Inc., 2014) ATAC *Automated Tactical Analysis of Crime*. Es una aplicación de análisis de delitos desarrollada por Bair Analytics, que dispone de herramientas de perfilado geográfico.

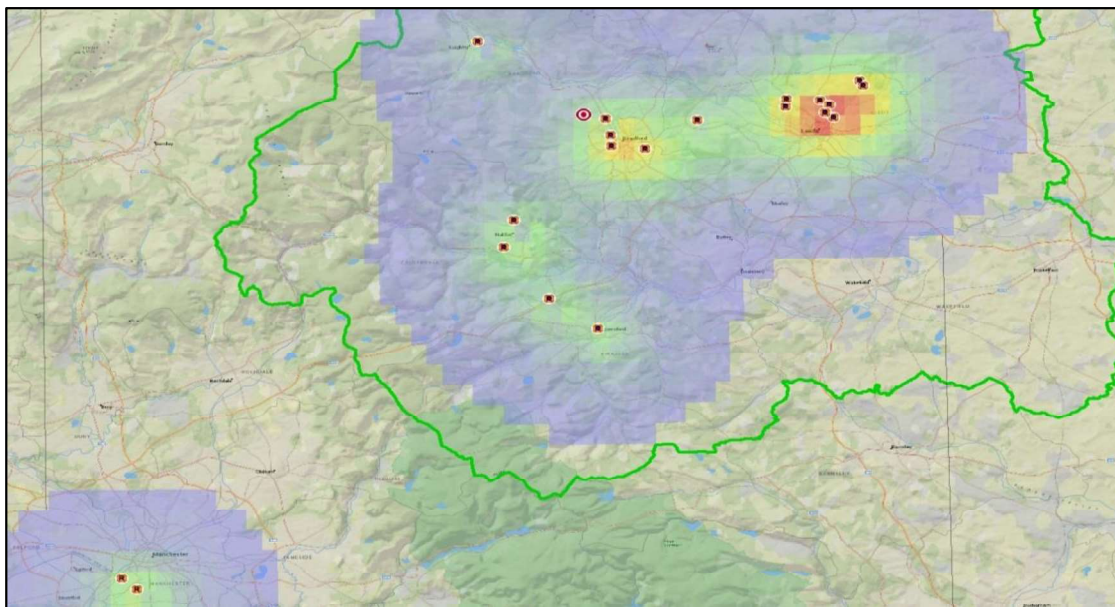


Figura 3-16: Geo Perfil Atac BairSoftware (Peter Sutcliffe)

- Perfil geográfico de delincuentes con hoja de cálculo. Para fines de investigación, el Dr. Kazunori Hanyu del departamento de Psicología de la Universidad Nihon, ha implementado un sistema de perfiles geográficos de delincuentes, utilizando una hoja de cálculo en lugar de programas sofisticados. El ajuste máximo del modelo son seis incidentes (Hanyu, 2019).

LS*		0	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8	8	9	9	10	10	11	11	12	12	13	13	14	14	15	15		
P(B A)		-8	-7	-7	-6	-6	-5	-5	-4	-4	-3	-3	-2	-2	-1	-1	0	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8		
0	7.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0		
0.5	7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
1	6.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
1.5	6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
2	5.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2.5	5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	4.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3.5	4	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	3.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4.5	3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
5	2.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
5.5	2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
6	1.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
6.5	1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7	0.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
7.5	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
8	-0.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
8.5	-1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
9	-1.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
9.5	-2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
10	-2.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
10.5	-3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
11	-3.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
11.5	-4	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
12	-4.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
12.5	-5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
13	-5.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
13.5	-6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
14	-6.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
14.5	-7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
15	-7.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

Figura 3-17: Perfiles geográficos de delincuentes con hoja de cálculo.

- Algoritmo Rossmo gvSIG (Suarez-meaney y Chias, 2017). La implantación del modelo matemático de Rossmo en gvSIG mediante script, realizado por Jazmín Palomares del equipo GTS de la Universidad Nacional Autónoma de México (UNAM).
- SPIDER (Spatial pattern analysis for investigative decision making exploration and response) (Paulsen, 2011).

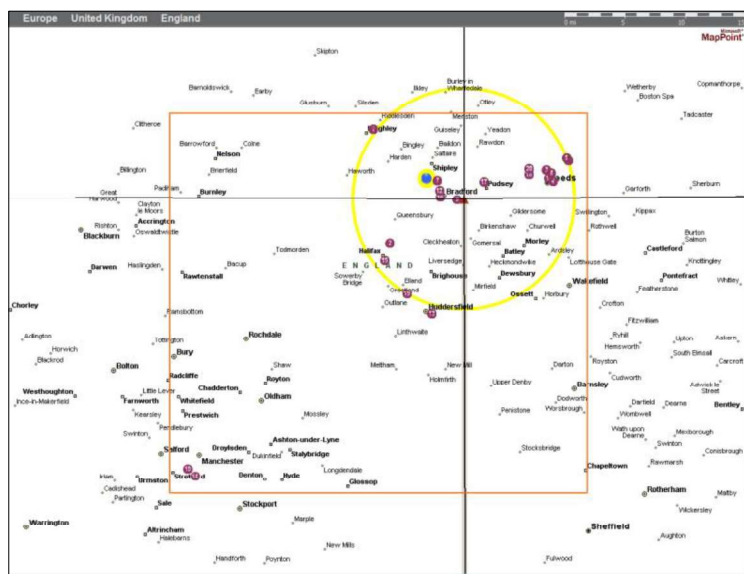


Figura 3-18: Perfil geográfico Spatial pattern analysis (Peter Sutcliffe).

- Modelo de perfil geográfico en el marco *Bayesian Dirichlet Process Mixture Model* (en adelante DPM) de (Verity, 2014), el modelo se implementó en R y proporciona una herramienta práctica para el criminólogo en la focalización de intervenciones y un uso más eficiente de los recursos para la investigación de delitos en serie. diseñado para colocar el perfil geográfico en un marco bayesiano y para tratar el tema de múltiples fuentes. El modelo DPM supone un gran número (estrictamente infinito) de ubicaciones de origen potenciales, aunque se supone que algunas de estas fuentes son más "activas" que otras. Eso amplía el enfoque de creación de perfiles fisiológicos integrando la idea de disminución de la distancia y zona de amortiguación. El software ha sido adaptado por la Universidad Queen Mary de Londres para ayudar a controlar los brotes de malaria (mapas de riesgo en epidemiología).

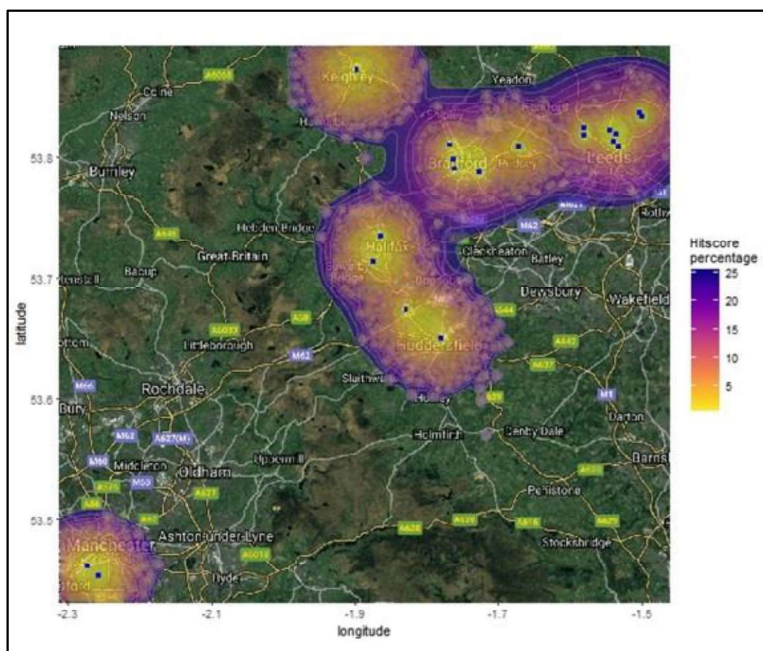


Figura 3-19: Algoritmo RgeoProfile (Peter Sutcliffe)

- GeoCrime (Butkovic, 2019) El software de creación de perfiles geográficos desarrollado por Asmir Butkovic; El programa se basa en el algoritmo de Rossmo y combina técnicas manuales (permite modificación de los parámetros (B, f, g, k) y automáticas para examinar la probable distribución espacial de los delitos utilizando herramientas de geocodificación y mapeo.

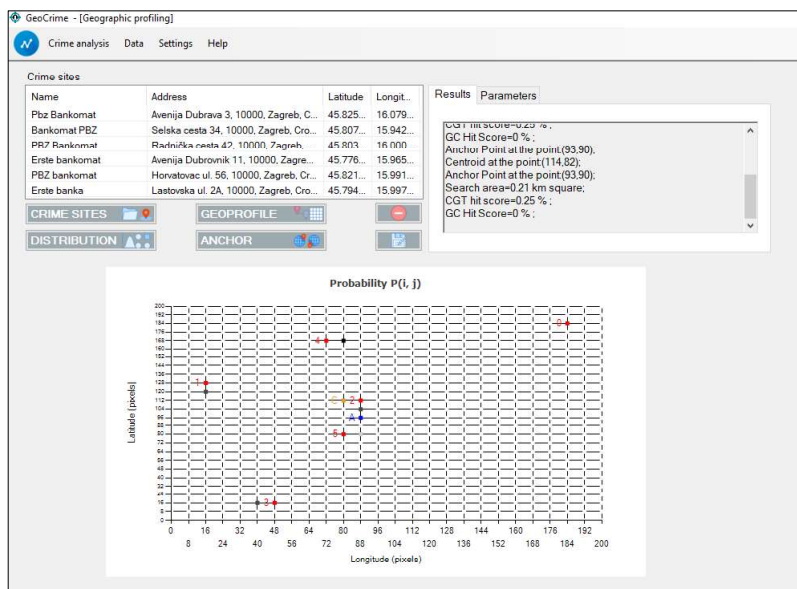


Figura 3-20: Modelo de Perfilado Geográfico GeoCrime

- El rgeoprofile: Geographic Profiling Methods for Serial Crime Analysis (Spaulding y Morris, 2021), paquete en R se contribuyó para proporcionar una plataforma de código abierto viable que consta de varias soluciones que se han propuesto, desarrollado y utilizado para modelar y evaluar el domicilio de un delincuente dada su serie de incidentes. El paquete incluye métodos para predicciones de puntos centrográficos (estrategias de distribución espacial) y funciones de disminución de distancia (estrategias de distancia de probabilidad).

3.2 Elementos

Área de actuación

El perfilador debe determinar la amplitud del área circundante a una serie de incidentes delictivos para que exista una probabilidad razonable de que el delincuente resida allí (véase figura 3-22). Aún no disponemos de un método que defina la dimensión de ese espacio en función de la probabilidad estimada de la presencia del delincuente. Por lo tanto, se destaca la importancia de establecer con precisión el área de estudio.

El área de actuación o la "zona de caza" de la residencia u otro punto de anclaje de un delincuente en serie constituye un grupo de lugares de comisión de delitos identificados y se define por un diámetro compuesto por los dos puntos más alejados (Warren, Reboussin y Hazel-wood 1995; Rossmo 2000).

La determinación del tamaño de la cuadrícula se realiza de manera subjetiva. No existe una base sólida para establecer los límites del área de búsqueda (van Der Kemp, 2014). Aunque es posible establecer un área más amplia que el límite mínimo establecido, hay que tener en cuenta el efecto de borde que puede generar el área de actuación definida. Las definiciones espaciales precisas de los límites de la cuadrícula varían algo entre los métodos de Rossmo (2000), Canter (2000) y Levine (2010). La distancia a la escena del delito se determina para cada celda de la cuadrícula (véase figura 3.6). Con base en la función de disminución de la distancia, se determina la probabilidad de la proximidad de la celda a un posible lugar del domicilio.

Las áreas son definidas por el rectángulo mínimo delimitador de los incidentes por un porcentaje, dependiendo de la herramienta utilizada *Geoprofile* 50% (562.500 celdas), *Dragnet* 10% (13.300 celdas), *ATAC* por un 10% y en el caso de *Rigel* (zona de caza) por la mitad de la distancia media entre puntos, con un total de 40.000 celdas.

Algunas de las aplicaciones de creación de perfiles geográficos también requieren que el usuario defina una referencia área. Se puede crear una cuadrícula de referencia en CrimeStat especificando las coordenadas mínimas-máximas de latitud y longitud, así como la resolución de la cuadrícula. CrimeStat también permite al usuario especificar un archivo de área de referencia que contiene una lista de coordenadas de latitud y longitud. Al crear manualmente un archivo de entrada, Dagnet requiere que el usuario defina un área de referencia especificando la longitud de los ejes X e Y en kilómetros. Debido a que Dagnet define el área de referencia como un rectángulo con una relación de aspecto de 133: 100, los ejes X-Y deben conservar esta relación. Rigel utiliza un algoritmo basado en la distancia media entre puntos para definir su área de referencia (Levine, 2004). La distancia media entre puntos X se suma a la ordenada X máxima y se resta de la ordenada X mínima. El proceso se repite para los valores de Y (véase ecuación 3.9 a 3.12).

En la aplicación GEO-SCRIPT (véase capítulo 7) se puede seleccionar varias opciones de áreas de actuación (figura 3-21).

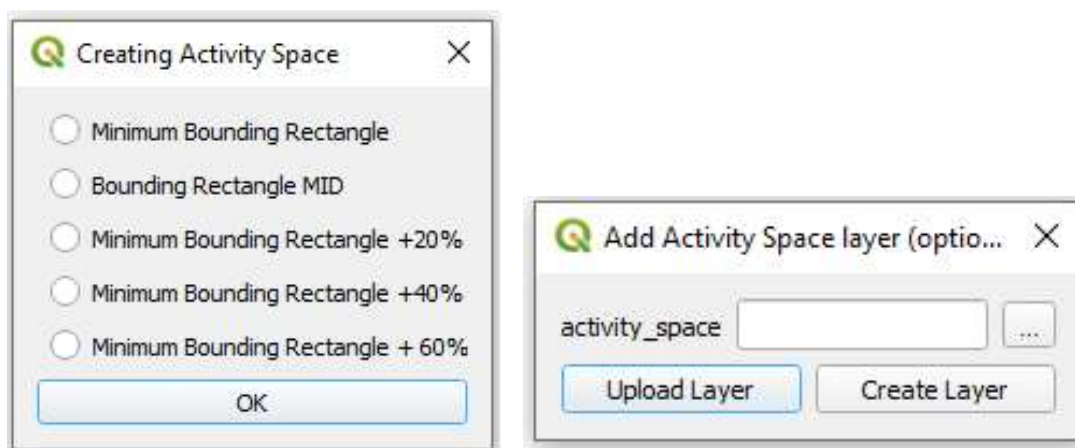


Figura 3-21: Modelo GEO-SCRIPT. Selección área de actuación.



Figura 3-22. Delimitación área de actuación.

Rossmo (1995) introduce el concepto de zona de búsqueda rectangular, también llamada área de caza. Los límites del mapa que delimitan el área de caza del delincuente en CGT se calculan primero a partir de los lugares del delito. En el caso de una cuadrícula de Manhattan orientada a lo largo de los ejes norte y este, los bordes se determinan agregando bordes iguales a la mitad de las distancias medias entre puntos x e y a los puntos más al este y oeste, y al norte y al sur, respectivamente, los límites se determinan de la siguiente manera:

$$y_{high} = y_{max} + (y_{max} - y_{min})/2(C - 1) \quad (3.9)$$

$$y_{low} = y_{min} - (y_{max} - y_{min})/2(C - 1) \quad (3.10)$$

$$x_{high} = x_{max} + (x_{max} - x_{min})/2(C - 1) \quad (3.11)$$

$$x_{low} = x_{min} - (x_{max} - x_{min})/2(C - 1) \quad (3.12)$$

donde:

y_{high} es el valor y del límite más al norte;

y_{low} es el valor y del límite más al sur;

y_{max} es el valor máximo de y para cualquier lugar del delito;

y_{min} es el valor mínimo de y para cualquier lugar del delito;

x_{high} es el valor de x del límite más este;

x_{low} es el valor de x del límite más oeste;

x_{max} es el valor máximo de x para cualquier lugar del delito;

x_{min} es el valor mínimo de x para cualquier lugar del delito;

C es el número de localizaciones del delito.

Rigel utiliza un rectángulo delimitador mínimo para su zona de caza, con una zona ampliada de la delimitación mínima para evitar los efectos de borde.

El efecto borde está presente en aquellas investigaciones que no tienen la capacidad de considerar comportamientos, objetos o eventos que ocurren fuera de la región geográfica estudiada, es decir, más allá de los límites de esa región (Rengert y Lockwood, 2009). Este problema aparecería, según Cruz Rot (2006), cuando los puntos que se ubican fuera de los límites del área de estudio no son considerados para estimar las características de un proceso puntual. Por lo tanto, se sugiere que este problema debe ser abordado, ya que ignorar sus efectos significa omitir

que cualquier distribución geográfica o interacción espacial que ocurra dentro de la unidad de análisis, puede extenderse más allá de sus límites (Gao et al.2017).

Aunque el problema del borde está presente en todas las escalas del análisis espacial, sus consecuencias se acentúan cuando se utilizan unidades geográficas pequeñas, como sectores censales, ya que la probabilidad de que los puntos se ubiquen cerca del eje es considerablemente mayor.

Maldonado (2022), señala que ignorar el efecto del borde podría tener consecuencias significativas en nuestros cálculos relacionados con los patrones espaciales de determinados fenómenos. Esta omisión podría influir negativamente en los resultados de las estrategias de perfilación geográfica del delito durante investigaciones criminales, así como afectar la precisión al estimar el número de delitos ocurridos en áreas específicas.

Salafranca et al (2021), proponen una nueva metodología que supera las limitaciones de otros enfoques que también se han utilizado para resolver el efecto borde al contar datos puntuales (véase anexo F).

Puntos de anclaje y conjuntos de ubicación delictiva.

Como puntos de anclaje fueron seleccionados exclusivamente aquellos lugares que permiten encontrarse en una investigación policial.

Estos puntos de anclaje son, a los efectos de este estudio, los siguientes:

1. domicilio del delincuente
2. antiguo domicilio del delincuente
3. lugar de trabajo del delincuente
4. domicilio de la familia primaria (padres, hermanos, hijos)
5. otros lugares en los que se sabe que el ofensor ha permanecido por largo tiempo.

La primera cuestión relativa a la dimensión espacial son los tipos de ubicación que pueden incluirse en el perfil. Un delito suele estar asociado con varios lugares, como la escena del contacto inicial, la(s) escena(s) del delito y la escena de la liberación/descubrimiento. Como conjuntos de ubicación delictiva se entienden, a los efectos de este estudio, todos los lugares en los que ocurrieron hechos relevantes para la comisión del delito. En especial se trata de:

1. el lugar del contacto (primer encuentro físico entre la víctima y el victimario)
2. el lugar de la agresión (el espectro abarca desde la amenaza verbal hasta la aplicación de violencia corporal pasando por la amenaza con armas)
3. el lugar de la violación o el delito sexual
4. el lugar del homicidio
5. el lugar en el que se depositó el cuerpo

Para asesinatos en serie, estos tipos de ubicación incluyen encuentro de víctima, ataque, asesinato y eliminación del cuerpo. Para la violación en serie incluyen el encuentro con la víctima, sitios de lanzamiento de ataque, violación y víctima. Incendio en serie normalmente implica solo una ubicación, el sitio de configuración de fuego. Ocho combinaciones posibles, denominadas conjuntos de ubicación delictiva, resultan de la cuatro diferentes tipos de sitios de asesinatos.

Rossmo (2000), distingue cuatro lugares de interés:

1. de lugar de encuentro, donde el delincuente ve a su futura víctima por primera vez
2. el lugar donde el delincuente ataca, donde domina a su víctima, que no necesariamente tiene que ser el lugar donde ocurre todo el delito, porque el delincuente a veces lleva a su víctima a un lugar donde comete el delito
3. el lugar donde se comete el delito es el siguiente lugar de interés
4. finalmente, el lugar donde el agresor abandona o suelta a su víctima.

Es posible que se trate de cuatro lugares diferentes, pero también es posible que todo suceda en uno o dos lugares diferentes. Sugiere que el grado de organización del perpetrador y su movilidad determinan cuántos lugares se utilizan en última instancia. La relación entre cada categoría y el camino hacia el crimen está lejos de ser idéntica. Rossmo (2000) no ha definido exactamente qué implica la planificación o la movilidad. Para determinar si es posible la elaboración de perfiles geográficos de delincuentes y es significativo, el lugar de la reunión y el lugar de descarga son relevantes. Para simplificar, Rossmo (2000) afirma que el lugar de la reunión y el lugar donde se vio a la víctima por última vez son los mismos, sin tener en cuenta que pueden ser lugares diferentes (van Der Kemp, 2014). No podemos presuponer cuál de estos lugares tiene una evaluación espacial más significativa con el punto de anclaje del delincuente en serie. Esta

conexión debe ser evaluada en base a la hipótesis espacial seleccionada para modelar el comportamiento del SHOs.

3.3 Medidas de precisión

La decisión metodológica necesaria para evaluar el software de creación de perfiles geográficos aborda cómo se mide la precisión de una aplicación. En este campo, se han implementado seis medidas de precisión clave de manera extensiva (Rich y Shively, 2004):

1. La distancia de error es la distancia en línea recta entre la ubicación inicial prevista (cuadrícula que representa la probabilidad máxima) y la residencia real del SHO (puntuación de acierto). El error de distancia proporciona una buena medida para evaluar la precisión espacial de un perfil geográfico (Kent, 2003).
2. La distancia de error de perfil es la distancia en línea recta entre la ubicación de inicio real y el punto más cercano en el borde de la región del perfil superior.
3. La distancia de error de perfil (modificada) es una medida que implica tomar la distancia euclidiana entre la dirección conocida y el eje más cercano del área de búsqueda final esperada de un perfil (es decir, el área de mayor superposición) donde las distancias más cortas indican mejores resultados. Al proporcionar una medida de qué tan lejos está el área de perfil superior de la ubicación real del delincuente, la puntuación del área de búsqueda de perfil es una medida que indica cuánto del área de búsqueda requerida fue estimada por el modelo. La puntuación se mide como la relación entre el área de búsqueda prevista (es decir, la salida modelada) y el área de búsqueda requerida (es decir, el área de búsqueda teórica necesaria para abarcar la residencia del SHO).

4. El área del perfil superior es la relación entre el área de la región del perfil superior y el área de referencia total, también llamada área de búsqueda prioritaria es parte del dominio del delito, donde los investigadores deben concentrarse en buscar la base de operaciones de un delincuente. Es el área de todas las celdas con una puntuación de probabilidad igual o superior a la puntuación de probabilidad asignada al "refugio" real (Pal, 2007).
5. La precisión del perfil es una prueba binaria de si la ubicación real de la casa se encuentra dentro de la región del perfil superior y se informa como "sí" o "no".
6. El coste de búsqueda es el porcentaje del área de referencia buscada antes de encontrar la ubicación real de la casa.

El porcentaje de puntuación (*Hit score percentage*) de acierto es la proporción del área buscada antes de que se encuentre la residencia del delincuente en el total del área de estudio (área de actuación). El área de búsqueda se estima utilizando la priorización de perfiles geográficos donde las celdas con la probabilidad o puntuación de probabilidad superior o igual a la probabilidad o puntuación de probabilidad de la celda que contiene el "domicilio" real. Una proporción menor indica un enfoque geográfico más preciso y una mejor predicción del modelo. El porcentaje de puntuación de aciertos es la mejor medida de la utilidad predictiva de un perfil geográfico, ya que esta medida no tiene desventajas intrínsecas. El grado de ajuste del modelo se puede calcular utilizando el porcentaje de puntuación de acierto (% HS), la proporción del área que cubre los delitos (en la que la base del delincuente se encuentra; en criminología, esta suele ser el área que delimita los delitos, más una "barrera de seguridad" del 10% que la rodea. El % HS se calcula dividiendo la puntuación clasificada por el área de búsqueda total y multiplicar por 100. Cuanto menor sea él % HS, más preciso será el perfil geográfico; una puntuación de aciertos del

50% es lo que se esperaría de una búsqueda no priorizada (es decir, aleatoria o uniforme) (Rossmo, 2000).

La efectividad de la elaboración de perfiles geográficos ha sido insuficientemente estudiada, pese a la existencia de ciertos informes que tratan sobre su precisión. Para abordar estas y otras cuestiones metodológicas, el NIJ Reunión un equipo de expertos relacionados con la creación de perfiles geográficos (Rich y Shively, 2004). Un informe final resume dicha discusión, proponiendo un esquema para evaluar el software geográfico. Sin embargo, Rossmo, (2005a) expresó desacuerdos con algunas conclusiones, proponiendo una metodología distinta.

El equipo del NIJ sugiero evaluar la precisión del software geográfico en diversas condiciones, similar a las que enfrentan los policías en investigaciones reales (Rich y Shively, 2004). Abogaron por la creación de un conjunto de datos con variados delitos y categorías de delincuentes, obtenidos de distintas jurisdicciones, teniendo en cuenta variables como el diseño de carreteras y barreras geográficas significativas. Además, destacaron la importancia de incluir series con al menos tres delitos y considerar delincuentes de tipo viajero, reflejando la incertidumbre que enfrentan los investigadores al desconocer la naturaleza de un delincuente serial.

El equipo de expertos fundó sus recomendaciones en la idea de que al evaluar el software en condiciones lo más cercanas a la realidad se obtendrán resultados más relevantes (Rich y Shively, 2004) No obstante, Rossmo (2005a) criticó la inclusión de casos que el software geográfico no estaba diseñado para manejar, sosteniendo que debería evaluarse en las condiciones operativas recomendadas.

Rossmo (2005) identificó tres problemas con la distancia de error;

- 1 Es lineal, cuando en realidad el error no lo es. La medida relevante es el área, que aumenta con el cuadrado de la radio (distancia de error).

- 2 No es una medida estandarizada debido a su sensibilidad a la escala.
- 3 Es que no refleja adecuadamente cómo funciona el software de perfiles geográficos.

Para determinar la utilidad de una herramienta de perfil geográfico, es esencial relacionar el lugar real de residencia del delincuente con la distribución de probabilidad que ofrece la herramienta. El índice de coste de búsqueda (Canter et al., 2000) sirve adecuadamente para ello, pues indica el porcentaje promedio del área que debe ser buscada para encontrar al delincuente (Bernasco, 2007).

Capítulo 4

ESTRATEGIAS DE PERFIL GEOGRÁFICO

Siguiendo la línea de trabajo de Brent Snook, Zito, et al. (2005), los algoritmos para el perfilado geográfico se dividen en dos categorías según su enfoque general.

4.1 Estrategias de distribución espacial

Este enfoque utiliza características geométricas de la distribución del delito para hacer una predicción de un solo punto. Entre las estrategias comunes de distribución espacial encontramos: el centroide, centro del círculo, mediana, media geométrica, media armónica y el centro de la distancia mínima.

En el ámbito de las ciencias geoespaciales, es común abordar las relaciones entre puntos ubicados en la superficie terrestre. Sin embargo, estos puntos suelen representarse como proyecciones sobre un plano, es decir, un mapa, y las zonas de interés se delimitan mediante polígonos.

La centrografía emerge como una técnica vital para ilustrar y cuantificar las características fundamentales de una distribución espacial. Esta herramienta se muestra esencial al facilitar análisis que evalúan tendencias discernibles y comparan distribuciones espaciales variadas relacionadas con la delincuencia.

Es crucial entender que el centroide de un polígono no necesariamente coincide con el centro de masa real del objeto representado, ya que estamos tratando con representaciones gráficas,

ya sea en papel o digitalmente. A menudo, se asume que el centroide equivale al centro geométrico del polígono. En situaciones con polígonos de formas complejas, determinar dicho centro puede ser una tarea con ciertas dificultades. Así, se recurre a ecuaciones matemáticas y sistemas de coordenadas cartesianas para calcular estos centroides, como señalan (Deakin et al., 2002).

Geodetic Glossary of the US National Geodetic (NGS 1986), define un centroide como: "El punto cuyas coordenadas son los valores promedio de las coordenadas de todos los puntos de la figura".

Este concepto del centroide de una figura como un punto que tiene valores promedios de las coordenadas y que comprende tres tipos de promedios; la media, la mediana y la moda (Reichmann, 1961).

Las tres son medidas de tendencia central;

El primer tipo de promedio, la media, puede subdividirse en media aritmética, media cuadrática media, media armónica y media geométrica, todo lo cual puede definirse utilizando dos ecuaciones (Apostol, 1967). La media p-ésima potencia M_p de un conjunto de números reales $x_1 x_2 \cdots x_n$ es

$$M_p = \left(\frac{x_1^p + x_2^p + \cdots + x_n^p}{n} \right)^{1/p} \quad (4.1)$$

donde el número M_1 es la media aritmética, el número M_2 es el cuadrado medio raíz y M_{-1} es la media armónica. La media geométrica G de un conjunto de números reales $x_1 x_2 \cdots x_n$ es

$$G = (x_1 x_2 \cdots x_n)^{1/n} \quad (4.2)$$

La media aritmética

El promedio proporciona una representación de la distribución de los datos (Bolle et al., 1973). En este contexto, puede referirse a la media aritmética de las coordenadas X e Y de una serie de delitos (véase figura 4-1). El punto medio obtenido a partir de esta media aritmética corresponde al punto con la coordenada X promedio y la coordenada Y promedio de todas las escenas del delito. Este punto se sitúa, aproximadamente, en la posición central entre todos los delitos registrados.

$$\bar{x} = \frac{\sum_{k=1}^n x_k}{n} \quad \bar{y} = \frac{\sum_{k=1}^n y_k}{n} \quad (4.3)$$

El punto medio aritmético suele ser efectivo para caracterizar un conjunto de puntos, sobre todo si ese conjunto no tiene valores extremos. Podríamos suponer que el delincuente vive cerca de este punto medio, similar a cómo algunas arañas se sitúan en el centro de su tela (Chrysanthus, 1947). Sin embargo, no hay fundamentos sólidos para asumir que el delincuente resida precisamente en ese punto central. Un desafío con el uso del promedio es su sensibilidad a la distribución espacial de los puntos. Por ejemplo, si se añade un punto extremadamente distante al conjunto de delitos, como un valor atípico, este influirá notablemente en la posición del punto medio aritmético. Como resultado, el punto central recalculado se desplazará hacia la dirección de ese valor extremo (véase figura 4-2 y 4-3).

Si existen puntos dispersos, los medios aritméticos no pueden ofrecer un resumen representativo del patrón general de ubicaciones. Puede darse cuenta del caso de que no se encuentre cerca de la residencia del autor. De hecho, es común que los delincuentes cometan muchos de sus delitos cerca de su domicilio, pero también en las cercanías de otros lugares

relevantes para ellos, como la casa de sus padres, la dirección de un traficante de drogas al que visitan con frecuencia, o una residencia vacacional (Brantingham y Brantingham, 1993; Polišenská, 2008). Al calcular la media, todas las coordenadas se tienen en cuenta, pero no se distingue entre estos diferentes focos de actividad.

Un ejemplo adicional de la limitación de los medios aritméticos se presenta cuando un delincuente comete varios delitos en una zona específica (parque) y otros en un área geográfica más amplia. La ubicación del parque influirá significativamente en los medios aritméticos debido al número concentrado de delitos. En todos los casos, valores extremos o atípicos dentro de un conjunto pueden influir considerablemente en el punto medio resultante del cálculo. Es esencial entender que, en conjuntos con un mayor número de delitos, estos valores extremos tienen un impacto menor en las medidas de tendencia central que en conjuntos con menos delitos. Es fundamental reconocer que la media aritmética es sensible a estas distorsiones

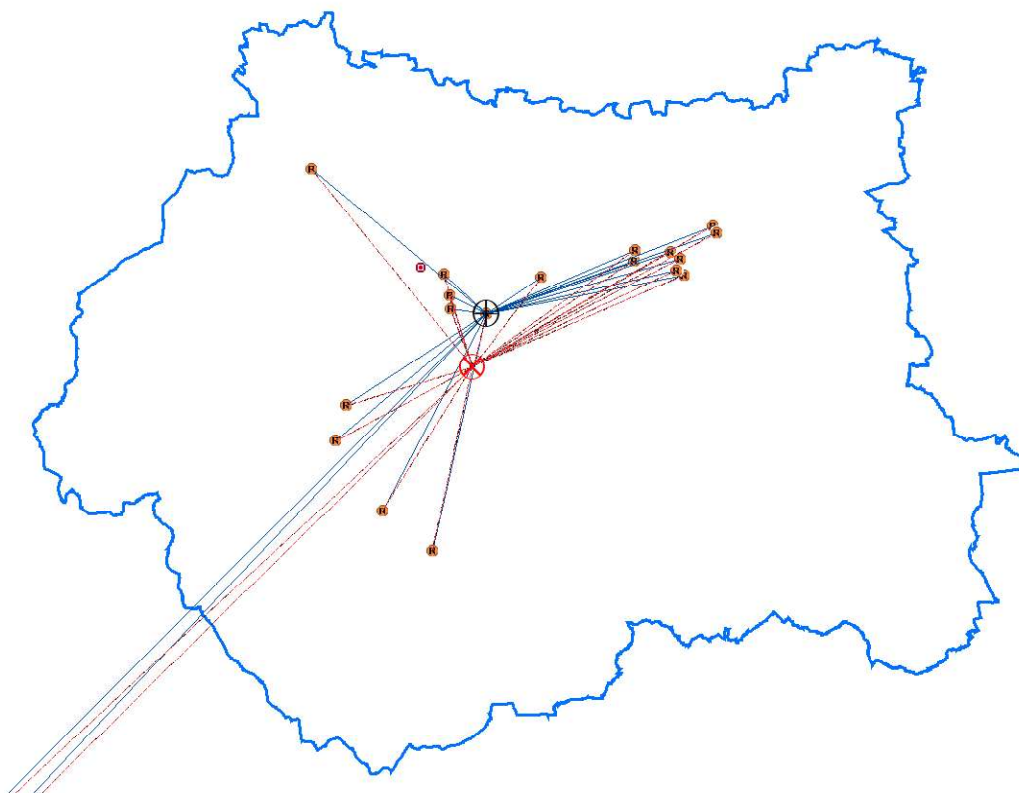


Figura 4-1. Media Aritmética y Centro mínima distancia. El círculo rojo corresponde a media aritmética, el círculo negro al centro de mínima distancia.

La media geométrica

Es una medida alternativa para la tendencia central, comparable a la media aritmética. No hay una gran diferencia entre la media geométrica y la media aritmética, al menos con un patrón uniformemente distribuido de escenas del crimen. La media geométrica busca un equilibrio en las relaciones entre los números, ya que la media aritmética busca el equilibrio en las diferencias. Sin embargo, la media geométrica es menos sensible a los valores atípicos (Bolle et al., 1973). Utilizando la ecuación 4.2 y tomando logaritmos naturales para superar los problemas numéricos que surgen con los productos largos, definimos el centroide medio geométrico (\bar{x}, \bar{y}) como

$$\ln \bar{x} = \frac{\sum_{k=1}^n \ln x_k}{n} \quad \ln \bar{y} = \frac{\sum_{k=1}^n \ln y_k}{n} \quad (4.4)$$

Al igual que con la media aritmética, no hay ninguna teoría al respecto comportamiento de viaje de los delincuentes como resultado del uso de la media geométrica. El método proporciona una caracterización de la serie de ubicaciones de delitos y es menos sensible a los valores atípicos. Algunos investigadores utilizan la media geométrica para evitar la distorsión de los valores extremos (LeBeau, 1987), mientras que otros utilizan estadísticas descriptivas adicionales como la moda (Rhodes y Conly, 1981), la distancia mínima y máxima del viaje delictivo (Canter y Larkin, 1993; Warren et al., 1995), el rango (Turner, 1969) y la información direccional (Rengert y Wasilchick, 1985).

La figura 4-2 y 4-3 muestra la media aritmética y geométrica. Se calculan con y sin valores atípicos. Se muestra que la media aritmética con el valor atípico se desplaza más hacia el valor atípico que la media geométrica.




Figura 4-2: Media aritmética y geométrica (con valores atípicos). El círculo negro corresponde a media aritmética, el círculo rojo a media geométrica.




Figura 4-3: Media aritmética y geométrica (sin valores atípicos). El círculo negro corresponde a media aritmética, el círculo rojo a media geométrica.

Otra medida de tendencia central es la mediana.

La mediana se establece no sumando valores, sino clasificándolos. En el caso de las coordenadas, para hallar la mediana de una serie numérica, se busca el valor en el cual el 50% de los números están por debajo y el otro 50% están por encima. Este procedimiento se aplica de forma individual para las coordenadas X e Y .

El centro de la distancia mínima

El centro de la distancia mínima de un conjunto dado de puntos en el espacio euclidiano bidimensional es la ubicación en la que la suma de las distancias a todos los demás puntos es la más pequeña (véase figura 4.1).

El centro de mínima distancia es esencialmente el punto más cercano a todos los otros puntos, convirtiéndose en un excelente indicador del punto de anclaje del delincuente (Levine, 2002). A pesar de que a veces se le denomina “centro mediano”, es esencial no confundirlo con el punto donde la media de las coordenadas X intersecta con la media de las coordenadas Y .

La determinación de un centro de mínima distancia exacto no se reduce a una fórmula o ecuación única. Como señala Mitchel (2005), este proceso es iterativo y complejo. Involucra calcular inicialmente un centro medio, sumar las distancias desde este centro a cada entidad, compensar el centro ligeramente y sumar las distancias nuevamente hasta que eventualmente se encuentre la ubicación óptima que minimiza la suma total de distancias.

Para la implementación se ha diseñado un script en lenguaje de programación Python con el algoritmo Weiszfeld, el código programado ha sido desarrollado por (Vardi y Zhang, 2000) (véase figura 7.6).

Weiszfeld (1936) propuso un algoritmo que estima la ubicación más probable de un hogar mediante un método iterativo, cuya fórmula es la siguiente:

$$(x^{(k+1)}, y^{(k+1)}) = \left(\frac{\sum_{i=1}^n x_i \left(\frac{1}{\text{dist}(x_i, y^{(k)})} \right)}{\sum_{i=1}^n \left(\frac{1}{\text{dist}(x_i, y^{(k)})} \right)}, \frac{\sum_{i=1}^n y_i \left(\frac{1}{\text{dist}(x_i, y^{(k)})} \right)}{\sum_{i=1}^n \left(\frac{1}{\text{dist}(x_i, y^{(k)})} \right)} \right) \quad (4.5)$$

donde el valor inicial $x^{(0)}, y^{(0)}$ puede tomarse como el centroide del conjunto de puntos dado. Kuhn (1973) demostró que el método en realidad converge al centro de la distancia mínima, pero no se conoce una estimación precisa de cuánto tiempo tarda el método en converger, en función del número de puntos de entrada. dados $(x^{(k)}, y^{(k)})$, el algoritmo de cálculo de $x^{(k+1)}$ e $y^{(k+1)}$ implica la inversa de las distancias entre $(x^{(k)}, y^{(k)})$ y los n puntos dados (Snook, Zito, et al., 2005).

Mientras que, Neldner (2015) destaca la precisión de este método para determinar la base del delincuente, Kent (2009) sostiene que supera a las estrategias de distancia de probabilidad.

Aunque las medidas como la media aritmética, cuadrática, armónica y geométrica, así como los centroides, son herramientas útiles, solo describen conjuntos de datos de puntos y no polígonos.

La forma más básica de estimar el punto central de un delincuente serial basándose en las ubicaciones de los crímenes es mediante un método centrográfico, ya sea el centroide o el centro de distancia mínima (LeBeau, 1987). Sin embargo, estos métodos pueden ser restringidos al analizar distribuciones ya que solo ofrecen una medida descriptiva. Por ello, se complementan con medidas de dispersión, como círculos, elipses y envolventes convexas.

Pero analizar las distribuciones utilizando este enfoque puede ser limitado, ya que solo son capaces de caracterizar procesos complejos con una sola medida descriptiva (Rossmo, 2000;

Levine, 2007). Como tal, el análisis centrográfico a menudo se ve incrementado por medidas de dispersión, incluidos círculos, elipses y cascos convexos.

Es relevante considerar que las estrategias de distribución espacial y probabilidad no siempre se adecuan a las funciones que localizan el punto central en un área específica, especialmente cuando no emplean funciones de decaimiento. Salafranca y Enzo (2022), clasificaron estas funciones como una estrategia de distribución de dispersión que utiliza características geométricas de la distribución criminal para hacer una predicción en un área específica.

Fortaleza y debilidades modelo

Estos métodos se definen como univariante medida de la tendencia central, la medida varía espacialmente según el estadístico elegido para sintetizar la distribución (centroide, media armónica, media geométrica, mediana, centro del círculo, centro de mínima distancia). Una ventaja de los modelos de distribución espacial es su facilidad de ejecución. Se basan únicamente en las ubicaciones de los delitos de la serie, que no requiere calibración con datos resueltos. Además, se calculan automáticamente para distancias euclidianas en software de análisis espacial (Trotta, 2014). Finalmente, su precisión al determinar la residencia del infractor ha demostrado ser alta, incluso mayor que los modelos de interacción espacial (Paulsen, 2006; Snook, Taylor, et al., 2005). Sin embargo, estos métodos adolecen de varios inconvenientes. En primer lugar, muchos de ellos son sensibles a los "valores atípicos". Esta sensibilidad puede ser muy problemática porque algunos delitos pueden atribuirse erróneamente a la serie. Algunos de estos sitios, ubicados en una posición extrema en la distribución, tendrán entonces una fuerte influencia en la ubicación del punto de anclaje (véase figura 4-2 y 4-3) Además, la extensión espacial del patrón no se tiene en

cuenta. Una distribución altamente concentrada produce el mismo punto de anclaje que uno muy disperso.

Otra limitación de los métodos centrográficos es que el resultado se limita a un solo punto y no proporcionan una estrategia de búsqueda sistemática (aunque todavía es posible priorizar la investigación alejándose gradualmente de la ubicación prevista). En cualquier caso, estos métodos no revelan cualquier dirección de investigación previa particular o áreas de búsqueda sucesivas espacialmente distantes.

4.2 Estrategias de probabilidad de distancia

Las estrategias de probabilidad resuelven este problema combinando un método del centro de gravedad con una función de disminución de la distancia para proporcionar información para cada coordenada del mapa (English, 2008). Para cada punto en un área de referencia que contiene la distribución del delito, se calcula un puntaje de probabilidad, también llamado densidad o puntaje de acierto, mediante el siguiente proceso:

- Primero, la distancia entre él y cada escena del delito se evalúa mediante una función de decaimiento de la distancia.
- En segundo lugar, los valores resultantes se suman para encontrar la puntuación de probabilidad. Cuanto mayor sea la puntuación, más probabilidades habrá de que sea el punto de anclaje del delincuente (Canter et al., 2000). Este enfoque permite a los investigadores visualizar un gradiente de probabilidades en el área de referencia, lo que les permite priorizar su búsqueda de manera más efectiva. El

contorno superior que contiene las puntuaciones de probabilidad más altas se denomina "región del perfil superior".

Las estrategias de probabilidad de distancia también conocidas como estimaciones de JTC (Levine, 2004), generan un perfil geográfico que comúnmente se visualiza en un mapa. La prominencia del perfil refleja la probabilidad de hallar el punto de anclaje en una ubicación específica. En este sentido, ofrecen una táctica de búsqueda estructurada que representa una ventaja destacable frente a las estrategias basadas en distribución espacial (Snook et al., 2005).

Los sistemas de perfiles geográficos han ganado gran expectativa en el ámbito investigativo, sirviendo no sólo como herramientas de indagación, sino también para modelar y describir patrones de desplazamiento hacia el lugar del delito. No obstante, aparte del trabajo de Canter et al. (2000), ha habido escasa reflexión sobre cómo distintas funciones impactan la operatividad de estos sistemas y que algoritmo matemático y parámetros resultaría más idóneo para ajustar aspectos de generación del modelo y describir las frecuencias de estos desplazamientos.

Actualmente, se utilizan cinco principales funciones de decaimiento en software de geolocalización: CGT, lineal logarítmico, exponencial, cuadrático y negativo. Estas funciones ayudan a cuantificar el efecto negativo del desplazamiento de un individuo respecto a su predisposición a delinquir, de manera que, a mayores distancias, decrece la probabilidad de cometer un delito. Cada función opera con una fórmula distinta y tiene variados efectos en esa relación. En el capítulo 13, se profundiza en este tema.

4.3 Estrategias de dispersion espacial

Utiliza características geométricas de la distribución del delito para hacer una predicción de un área determinada (Salafranca, 2020; Salafranca y Enzo, 2022). Entre las estrategias comunes de dispersión espacial encontramos:

Envolvente convexa mínima (convex hull polygon)

Define el polígono convexo de menor área dentro del cual se contienen todos los puntos del conjunto, y su significado tanto geográfico como geométrico es de gran utilidad en muchos aspectos. Su relevancia en campos geográficos y geométricos es inmensa.

Una manera sencilla de visualizar la envolvente convexa mínima es imaginar que los puntos están rodeados por una goma elástica. La forma que adopta esta goma es precisamente la de la envolvente convexa. A pesar de que visualmente es fácil identificar este polígono a partir de un conjunto de puntos, su cálculo matemático es más complejo de lo que parece (véase figura 7-19).

Esta envolvente es crucial al determinar el área dentro de la cual se puede predecir el comportamiento de una variable basándonos en muestras específicas. Por ejemplo, al interpolar un conjunto de datos, los valores estimados dentro de la envolvente son el resultado de una interpolación. Por otro lado, predecir valores fuera de esta envolvente sería un acto de extrapolación.

Además, el polígono que forma la envolvente puede ser utilizado como entrada para otras operaciones geométricas. Warren et al. (1998) sugirieron una definición adicional basada en un casco convexo para realizar una clasificación entre merodeadores y viajeros, que incluye todos los incidentes atribuidos a un delincuente.




Figura 4-4: Envoltente convexa mínima (convex hull polygon).

Modelo Newton-Swoope

Muy posiblemente la primera aplicación de análisis geográfico con objeto de identificar y caracterizar el comportamiento espacial del delincuente en relación con el lugar del crimen fue desarrollada a mediados de 1980 por el Profesor de Geografía de la Universidad Estatal de Luisiana, Milton Newton, investigación que influyó en métodos desarrollados más tarde en el

perfilado geográfico (Kent et al., 2006). El modelo se desarrolla de forma ampliada en los capítulos 10 y 11.

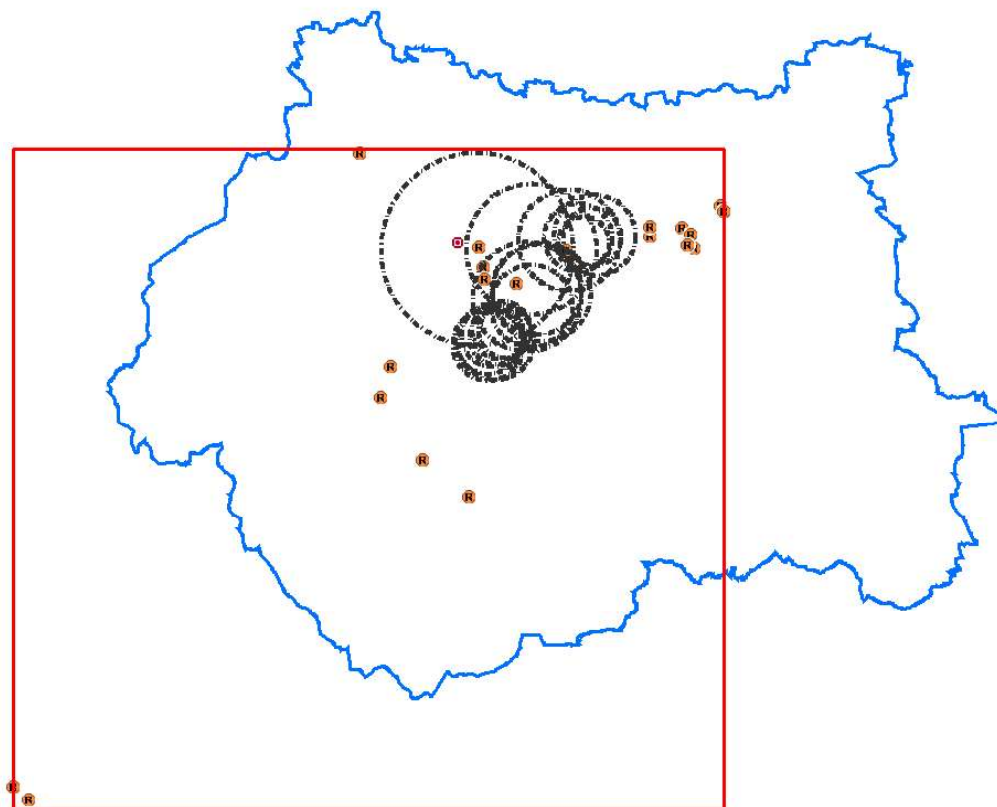


Figura 4-5: Modelo Newton-Swoope

Círculo mínimo

El círculo mínimo es aquel círculo que contiene a todos los puntos de un conjunto dado con el menor radio posible. El significado de este círculo mínimo es variado, ya que tanto el centro como el radio de este se prestan a diversas interpretaciones.

Canter y Gregory (1994) ampliaron el marco de modelado creado por Newton y Swoope, y los conceptos establecidos por la criminología ambiental para demostrar cómo se puede utilizar un modelo geográfico simple para indicar la residencia de un violador en serie. Conocida como la hipótesis del círculo, los investigadores pudieron identificar con precisión la residencia de los violadores al usar la distancia entre las dos escenas del crimen más lejanas como el diámetro de una serie de círculos colocados alrededor de los sitios del primer delito.

En su representación más simple, el patrón físico del movimiento del delincuente puede concebirse como un círculo que abarca la ubicación del hogar en el centro. El radio del círculo es representativo de la distancia entre la base de operaciones del infractor y el sitio del delito más alejado. Se propone que el comportamiento espacial del delincuente en una serie de delitos sea interpretable en relación con su base de operaciones, ya que todos los sitios de delitos serán relativos a esta ubicación (Canter y Larkin, 1993). La distancia entre la base de operaciones y el mayor delito se conoce como el "rango criminal", definido por la mayor distancia que un delincuente está dispuesto a viajar para cometer un delito (Canter y Gregory 1994). La propuesta clave de la "teoría del círculo" de Canter (Canter y Gregory, 1994; Canter y Larkin, 1993) es la existencia de una base fija desde la cual viaja el delincuente para ofender en un área definida (véase capítulo 12).




Figura 4-6: Círculo mínimo.

La distinción propuesta entre merodeadores y viajeros surgió originalmente del modelo de Canter y Larkin (1993) del comportamiento espacial de los delincuentes durante la ejecución de delitos en serie. Este modelo se conoce como la teoría del círculo del rango ambiental y describe el comportamiento espacial criminal como teniendo una relación significativa con la base de origen o el lugar de residencia del delincuente. Durante el movimiento criminal y no criminal desde la base de operaciones, los delincuentes adquieren conciencia de su entorno y, posteriormente, utilizan esta información para identificar posibles objetivos (Meaney, 2004).

Más allá de su interpretación geográfica, el círculo mínimo ofrece una perspectiva adicional. Es común que los puntos ubicados en su perímetro sean excluidos, dado que representan las posiciones más distantes y, en muchos casos, se consideran como valores atípicos que no reflejan adecuadamente el conjunto general. Es importante destacar que aquellos puntos en el borde del círculo mínimo también forman parte de la envolvente convexa mínima. Por esta razón, el desafío de calcular el círculo mínimo para un conjunto de n puntos puede simplificarse al enfocarse únicamente en aquellos puntos que integran la envolvente convexa mínima.

Diagrama de Venn

Las ayudas visuales, como los diagramas de Venn, son útiles para comprobar la validez de los teoremas de la teoría de conjuntos o para sugerir métodos que permitan demostrarlos.

Las operaciones de solape en los diagramas de Venn son equivalentes a las expresadas en el álgebra de mapas mediante funciones locales. Estas operaciones, esenciales en la creación de nuevas capas vectoriales, permiten combinar dos capas preexistentes. Aunque estas capas originales pueden contener diferentes tipos de entidades, combinadas se refieren a regiones o polígonos. Es importante destacar que estas operaciones de solape difieren significativamente de sus contrapartes en formato ráster. Se fundamentan en cálculos geométricos que aprovechan las coordenadas de cada entidad para derivar nuevas entidades. Estas operaciones se asemejan a operaciones de conjuntos y se pueden visualizar a través de diagramas simples, similar a los diagramas de Venn.

La Figura 4-7 muestra un diagrama de Venn para tres problemas hipotéticos en serie. Los círculos mediales que rodean la ubicación de cada crimen están definidos por un radio igual a la distancia de movilización de los crímenes, dentro del rango en el que se produce el porcentaje ρ

de las fallas del delincuente ($d = 2$ millas; $p \geq 0.70$). La probabilidad de que la residencia del delincuente se encuentre dentro del área circunscrita por un solo círculo es, por lo tanto, también p . Debido a que los delitos están conectados, es más probable que las áreas de solapamiento entre dos círculos cualquiera contengan la residencia del delincuente. La probabilidad más alta es en la región central donde se intersecan los tres círculos.




Figura 4-7: *Journey to crime*. Diagrama Venn. Tomado de *Geographic profiling: target patterns of serial murderers* (p.218) por Rossmo, 1995.

El método del diagrama de Venn se puede aprender fácilmente y aplicado y por lo tanto es muy adecuado para la práctica de detección. Sin embargo, hay tres inconvenientes del método del diagrama de Venn. Por ejemplo, no está claro qué radio del círculo se puede usar en delitos donde se sabe poco sobre el comportamiento de los delincuentes en los viajes. Además, a menudo ocurre que no todos los círculos se superponen (Bots, 2010; Koppen et al., 2002). En cualquier caso, esto

es así, si una serie de escenas de delitos son valores atípicos geográficos. Uno puede entonces ser capaz de usar un área de superposición que está determinada por un gran número de delitos, pero no todos. Hasta qué punto este conjunto más limitado de círculos es representativo del lugar de residencia del delincuente no está claro (véase figura 4-8). Tampoco está claro si debería haber un número mínimo de círculos superpuestos para dar una buena predicción del lugar de residencia del perpetrador (van Der Kemp, 2014).

La aplicabilidad sencilla y la flexibilidad constituyen las ventajas primordiales del método del diagrama de Venn (véase capítulo 9).




Figura 4-8. Diagrama de Venn (zona ampliada). La superficie en rojo es la zona más solapada.

Elipse de desviación estándar

Como alternativa al círculo, el modelo de elipse de desviación estándar puede explicar mejor las irregularidades en el paisaje. Al igual que el círculo, la elipse es capaz de identificar el centro de una distribución, así como la dispersión como la dirección de la de la dispersión. Pero a diferencia del círculo, una elipse mide la forma y orientación de la distribución al resumir la varianza máxima y mínima a lo largo de los ejes x e y (Ebdon, 1988). Como resultado, la elipse puede dar cuenta de un arreglo no uniforme de eventos (Lefever, 1926; Levine, 2007).




Figura 4-9: Elipse de desviación estándar.

La relación espacial entre las ubicaciones de la residencia de un delincuente y los sitios delictivos vinculados exhibirá patrones espaciales y características que sean consistentes con el paisaje subyacente. En consecuencia, un modelo de perfil geográfico que sea capaz de medir la ubicación, dispersión y orientación de las escenas del crimen debería predecir con mayor precisión

la ubicación residencial de un delincuente en serie (Kent, 2009). Además, debido a que el paisaje tiene un efecto determinista en la distribución del crimen en serie, la orientación de los perfiles elípticos debe correlacionarse con la orientación de las características del paisaje que coinciden con la extensión espacial de las escenas del crimen. Estas medidas pueden lograrse utilizando un modelo de elipse de desviación estándar similar al propuesto por Lefever (1926) y luego modificado por Levine (2007), Ebdon (1988) y Yuill (1971).

La elipse de desviación estándar es una elipse estadística que proporciona dispersión de los incidentes alrededor del centro medio en dos dimensiones (Ebdon, 1988; Cromley, 1992).

El eje Y gira en sentido horario a través de un ángulo θ , donde

$$\theta = \frac{\tan^{-1}\{[(\Sigma(X_i-\bar{X})^2 - \Sigma(Y_i-\bar{Y})^2) + [(\Sigma(X_i-\bar{X})^2 - \Sigma(Y_i-\bar{Y})^2)]^2 + 4(\Sigma(X_i-\bar{X})^2 - \Sigma(Y_i-\bar{Y})^2)]^2\}}{2\Sigma(X_i-\bar{X})(Y_i-\bar{Y})} \quad (4.6)$$

3) El eje X y el eje Y de la elipse están definidos por, longitud $x = 2s_a$, longitud $y = 2s_b$ donde

$$s_a = \sqrt{\frac{2}{k-2} \times \Sigma[x, -\bar{x}] \cos \theta - \Sigma(y_i - \bar{y}) \sin \theta]^2} \quad (4.7)$$

$$s_b = \sqrt{\frac{2}{k-2} \times \Sigma[x, -\bar{x}] \sin \theta - \Sigma(y_i - \bar{y}) \cos \theta]^2} \quad (4.8)$$

Dadas todas las ubicaciones de incidentes $\{(X_i, Y_i), i = 1, 2 \dots k\}$ (se muestra en puntos azules alrededor de las ubicaciones de los incidentes, como se muestra en la figura 4-10, El valor medio de todas las ubicaciones de los incidentes \bar{x} \bar{y} y otros estadísticos θ , s_a , s_b se puede

calcular. Entonces se puede trazar una desviación estándar alrededor de los lugares de incidencia, como se muestra en la figura 4-10.

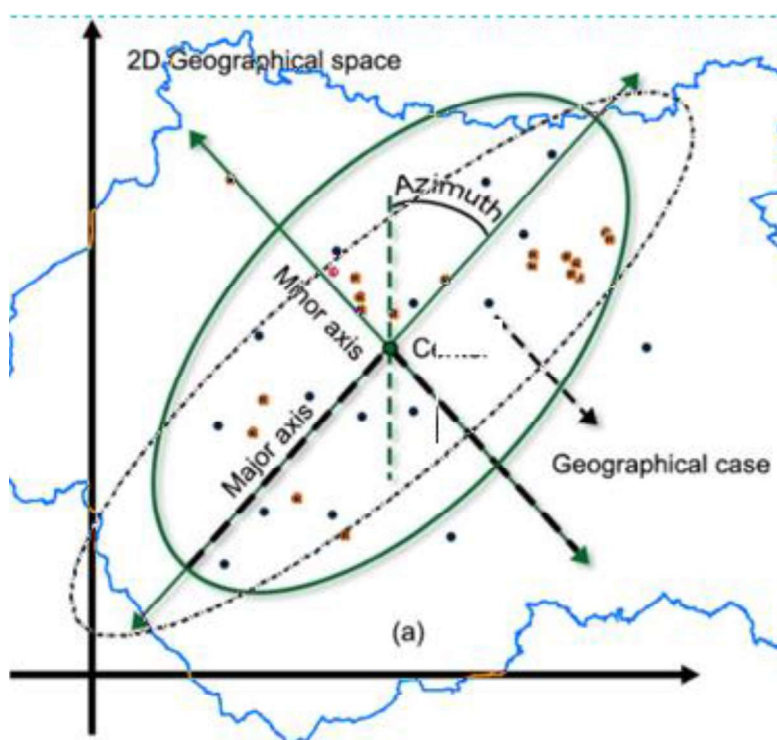


Figura 4-10: Elementos básicos de la elipse de desviación estándar. s_a corresponde al eje mayor y s_b corresponde al eje menor y θ corresponde al azimut. Adaptado de *Assessing Spatial Behavior Focusing on the Day and the Night Differences Using Social Media, GIS, and Spatial Statistics* (p.25) (Tukel, 2021).

Priorización del centroide aritmético

Uno de los métodos más simples para el perfil geográfico es el denominado Priorización del Centroide Aritmético, desarrollado por el profesor Derek Paulsen³ de la *Esatern Kentucky University* en el que se determina la orientación de la serie delictiva a un análisis de perfil geográfico o de predicción.

El método de Perfiles Geográficos dentro de SPIDER (Paulsen, 2011) se basa en el centro de mínima distancia (CMD). Este método se basa en esta investigación previa, pero crea un método de área de búsqueda que se basa en la distancia media desde los lugares del delito y el CMD.

³<https://cjregional.eku.edu/people/paulsen>

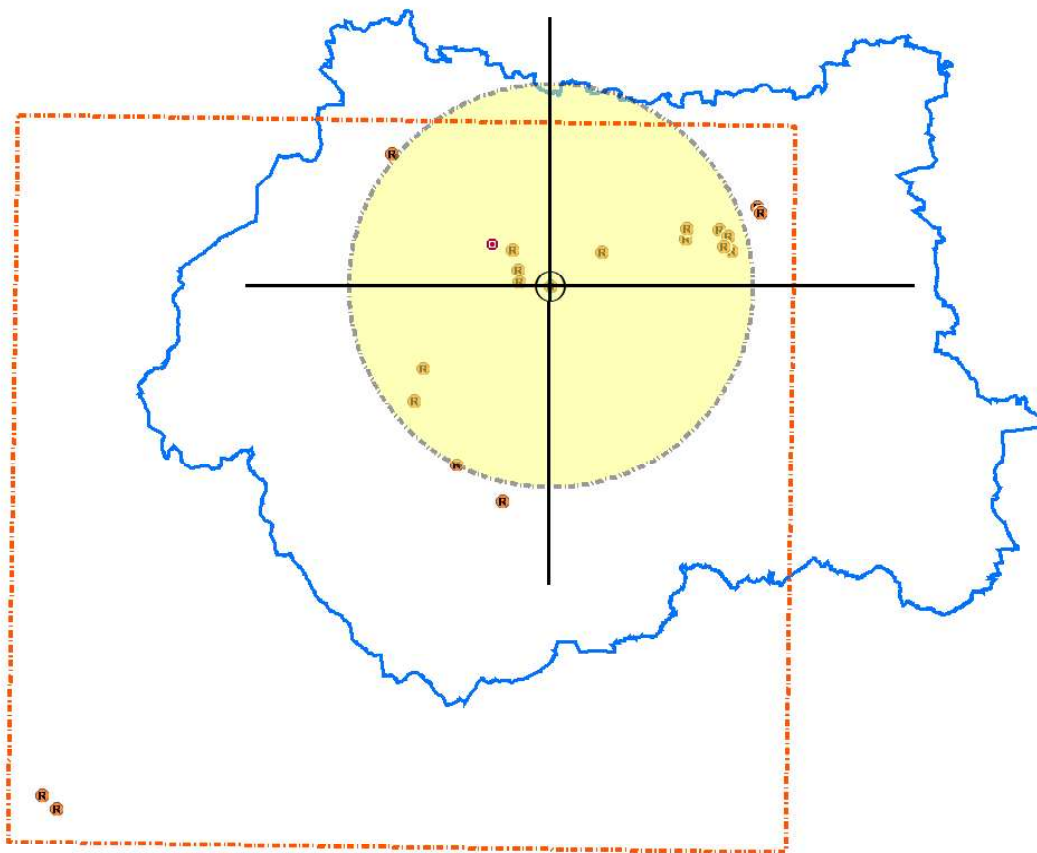


Figura 4-11: Priorización el Centroide Aritmético.

El modelo se basa en un algoritmo de cinco pasos:

1. Define un área de actuación formada por el rectángulo mínimo delimitador de todos los delitos más el 20%.
2. Realiza el cálculo del centro de mínima distancia (CMD), que define el punto en el que la distancia a todos los demás puntos es mínima (véase capítulo 7) figura 7.2.5
3. Identifica cuatro cuadrantes basados en la localización del CMD, intersectando dos líneas al CMD y calcula el porcentaje de incidentes en cada cuadrante
4. Calcula la distancia media entre los incidentes y el CMD.

5. Genera un círculo de radio igual al resultado del punto 4.

En la práctica, los resultados deben interpretarse como indicadores de que la base del delincuente (merodeador) es más probable dentro del círculo. El desglose del cuadrante es particularmente útil para la interpretación, proporciona un porcentaje de delitos que ocurrieron dentro de cada uno de los cuatro cuadrantes centrados en el CMD. Este análisis por cuadrantes se usa para ayudar a priorizar y reducir el área del perfil, permitiendo una focalización más efectiva de los recursos. En particular, aquellos cuadrantes con el mayor porcentaje de delitos tienen más probabilidades de contener el punto de anclaje.

Si el área de perfil es demasiado grande para ser prácticamente útil, entonces puede priorizarse mediante cuadrantes utilizando el sistema de clasificación de cuadrantes

Rectángulo delimitador mínimo

El rectángulo mínimo es el rectángulo de menor área que cubre todos los puntos de un conjunto. A menudo, el rectángulo con el área más pequeña también tiene el menor perímetro. Sin embargo, esto no es una constante. A pesar de ello, el rectángulo con el menor perímetro aún satisface la condición relacionada con la envolvente convexa. Por lo tanto, su determinación puede realizarse mediante un método similar.

El método más sencillo para encontrar el rectángulo delimitador mínimo implica recorrer los bordes del polígono convexo. Para cada uno de estos bordes, se determina el rectángulo delimitador más ajustado que comparte un lado con dicho borde del polígono. De estos rectángulos generados, se selecciona aquel con el área más reducida.

Para obtener el rectángulo delimitador de un borde específico, se proyecta el polígono sobre la línea que representa ese borde. La mayor distancia entre los puntos proyectados define el ancho del rectángulo. A continuación, se proyectan los vértices del polígono sobre una línea perpendicular al borde en cuestión. La distancia máxima entre estos puntos proyectados determina la altura del rectángulo. Usando el borde del polígono como referencia, es posible calcular tanto las orientaciones de los ejes del rectángulo como sus dimensiones en esas direcciones.

Visualmente, este rectángulo se representa trazando líneas a través de las coordenadas X e Y mínimas y máximas de un conjunto de datos. El resultado es el rectángulo más ajustado que logra englobar todos los elementos dentro del conjunto de datos.

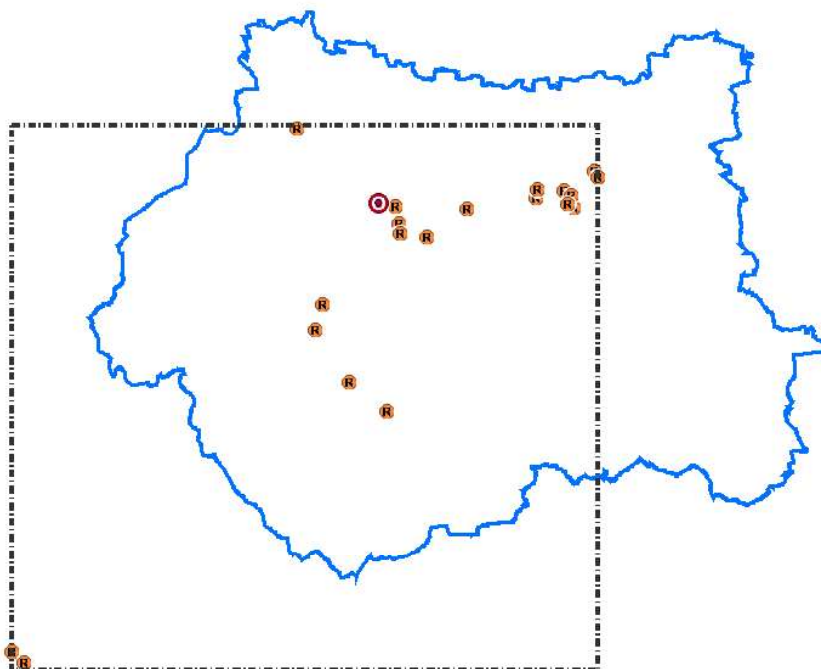


Figura 4-12: Rectángulo delimitador mínimo.

PARTE II ESTUDIO EMPÍRICO I

Capítulo 5

ESTUDIO EMPÍRICO

La investigación teórica llevada a cabo en la primera parte de esta tesis doctoral ha identificado diversas deficiencias en los métodos convencionales de perfilación geográfica. Una de las principales críticas es su falta de aplicabilidad práctica. En investigaciones recientes, surge la incertidumbre sobre si la perfilación geográfica puede realmente ofrecer resultados relevantes y efectivos.

5.1. Objetivos

Con el desarrollo de esta tesis doctoral se pretende dar una nueva visión en los aspectos con más debilidades en la metodología de perfiles geográficos, identificar dónde se pueden encontrar los problemas, las soluciones sobre cómo se pueden mejorar los perfiles geográficos y en qué contexto de investigación es apropiado su uso.

El objetivo principal de esta tesis doctoral es discernir y entender las limitaciones y factores que influyen en la elaboración de un perfil geográfico eficiente. Para ello se analizarán aquellas variables que estarían efectivamente disponibles durante una investigación en curso, asegurando así una mayor relevancia y aplicabilidad de los hallazgos.

Otro de los objetivos que se pretende alcanzar, es el de contribuir con un amplio conocimiento y comprensión de la metodología en entornos operativos, es decir, el uso de perfiles geográficos durante las investigaciones policiales.

Para poder alcanzar el objetivo general, se presentan los siguientes objetivos específicos:

1. Examinar las discrepancias en la efectividad de la perfilación geográfica criminal. A través de este enfoque, buscamos validar la afirmación de Levine (2002) que sugiere que individuos con formación básica podrían lograr resultados comparables a los producidos por herramientas de software especializadas en perfilación geográfica delictiva. Los resultados de este objetivo se corresponden con el capítulo 8.
2. Evaluar las estrategias de dispersión de perfilado geográfico. Con este objetivo pretendemos conocer si las estrategias establecidas se adaptan a los algoritmos de perfilado geográfico. Los resultados de este objetivo se corresponden con el capítulo 9.
3. Evaluar y modificar el modelo de perfilado geográfico de Newton y Swoope, aplicando el algoritmo de *Weiszfeld*, para mejorar la robustez de los datos en presencia de valores atípicos. Los resultados de este objetivo se corresponden con el capítulo 10 y 11.
4. Analizar las limitaciones del software de creación de perfiles geográficos. Con este objetivo pretendemos determinar si el tipo de delincuente (merodeador o viajero) se puede determinar de manera precisa y sistemática antes de comenzar un perfil geográfico utilizando datos de casos básicos conocidos en el transcurso de una investigación abierta de una serie delictiva. Los resultados de este objetivo se corresponden con el capítulo 12.

5. Examinar cómo el perfil geográfico tiende a subestimar la complejidad de las interacciones entre múltiples factores cognitivos, motivacionales, ambientales y otros relacionados, que determinan el comportamiento del delincuente. La conclusión, la teoría del decaimiento de distancia parece una simplificación excesiva de las relaciones complejas entre muchos predictores que desempeñan un papel en los modelos de estrategia de distancia de probabilidad. Las conclusiones de este objetivo se corresponden con el capítulo 13.
6. Explorar la influencia de los nodos y rutas en el marco de la llamada *Journey to crime*, comparando tres medidas de distancia; directa (Euclidiana), indirecta (Manhattan) y distancias funcionales, concretamente métricas calculadas con el algoritmo *Dijkstra's*. Los resultados de este objetivo se corresponden con el capítulo 14.
7. Comprobar una metodología que permita establecer criterios para medir la consistencia direccional de los delincuentes seriales (merodeadores y viajeros), utilizando herramientas de la estadística circular (*Rayleigh's test*). Los resultados de este objetivo se corresponden con el capítulo 15.

5.2. Hipótesis

De estos objetivos específicos se derivan las siguientes hipótesis:

Hipótesis 1. Los sistemas de software basados en estos algoritmos matemáticos ofrecen una mayor precisión que las predicciones realizadas por expertos humanos mediante un enfoque clínico.

Hipótesis 2. Mediante el análisis de las estrategias de distribución de dispersión y la construcción de un modelo de perfil geográfico basado en la teoría de conjuntos, podremos determinar con mayor precisión un área de referencia desde la cual iniciar la búsqueda del punto de anclaje de un SHOs.

Hipótesis 3. Basándonos en los supuestos propuestos por Newton (1988) y utilizando el algoritmo de Weiszfeld, observaremos mejoras en los valores atípicos en las tres condiciones de la metodología propuesta.

Hipótesis 4. Mediante el uso de técnicas de aprendizaje automático supervisado, es posible clasificar a los SHOs como merodeadores o viajeros con la información obtenida durante sus series criminales, y que esta clasificación puede facilitar y mejorar la precisión en la selección o priorización al realizar un perfil geográfico.

Hipótesis 5. La precisión del perfil geográfico en estrategias de distancia de probabilidad podría mejorarse integrando la anisotropía espacial.

Hipótesis 6. Hipotetizamos que los delincuentes de homicidio en serie pueden ser categorizados como merodeadores o viajeros medidos en la consistencia direccional observada durante sus series criminales.

Capítulo 6

MÉTODO

La eficacia del perfilado geográfico se asienta sobre tres pilares fundamentales:

- **Conceptualización y clasificación del grupo de delincuente:** Esta fase es de vital importancia, ya que la calidad y relevancia de la información recabada establecerán los cimientos para el análisis subsiguiente.
- **Desarrollo de una metodología de búsqueda espacial:** La primera consideración es determinar si es viable extrapolar o discernir el comportamiento espacial del delincuente basado en datos investigativos. Esta reflexión es crucial, ya que establece la premisa fundamental del perfilado geográfico. Es imperativo preguntarse: ¿Permiten los datos actuales una inferencia precisa sobre las tendencias espaciales del delincuente antes de ser detenido?
- **Supuestos subyacentes al algoritmo del perfilado geográfico:** Cada algoritmo de perfilado geográfico opera bajo determinadas premisas que reflejan patrones y comportamientos espaciales del delincuente. Un supuesto recurrente es la existencia de una relación inversa entre la proximidad de los delitos y el punto de anclaje o residencia del delincuente. Sin embargo, existen otros supuestos específicos, como la distribución de objetivos potenciales o la configuración geográfica de las escenas del crimen en relación con el punto de anclaje.

Si bien es esencial que exista una base sólida en la metodología de búsqueda espacial, es igualmente crucial que los supuestos del algoritmo sean adecuados para el caso en estudio. Si se valida la metodología, pero los supuestos del algoritmo no se ajustan a la realidad, es pertinente considerar enfoques alternativos.

Por ejemplo, si una serie particular de delitos no se alinea con los supuestos tradicionales, podría ser propicio identificar patrones únicos a esa serie. De esta forma, se abre la puerta a la creación de metodologías innovadoras, ajustadas a las particularidades de cada caso, tal como lo demuestra el estudio de Kasprzyk et al. (2013).

En conclusión, el perfilado geográfico es una herramienta compleja y detallada que se beneficia de un enfoque adaptativo, ponderando tanto las bases metodológicas como las especificidades de los algoritmos empleados. Este enfoque representa un equilibrio entre una comprensión general y una minuciosa atención al detalle, aspectos cruciales en el campo en constante evolución de la criminología moderna (Trotta, 2014).

El objetivo de esta tesis doctoral es desarrollar un procedimiento para evaluar la efectividad del perfilado geográfico. Para ello, es fundamental considerar el grupo de delincuentes seleccionados en la muestra y las variables espaciales de los lugares de los delitos que están directamente disponibles para la investigación.

El proceso de gestión de la información se inicia con la crucial tarea de exploración de datos y antecedentes. Esta fase es de vital importancia, ya que la calidad y relevancia de la información recabada establecerán los cimientos para el análisis subsiguiente. No obstante, antes de sumergirse en la etapa de búsqueda, resulta esencial poseer una comprensión clara de los objetivos a alcanzar. Es imprescindible discernir qué datos ya se encuentran a nuestra disposición, identificar qué información adicional requerimos.

Hernández et al. (2010) subrayan que, al seleccionar una muestra, es esencial que esta represente fielmente a la población global que se investiga. En el contexto de nuestra tesis doctoral, hemos considerado meticulosamente este principio. De esta manera, determinamos subconjuntos de Delincuentes de Homicidio en Serie (en adelante SHOs) basados en las regiones donde se llevaron a cabo los delitos (véase figura 6-2).

León y Montero (2018) sostienen que los individuos seleccionados para conformar una muestra deben satisfacer tres criterios esenciales: representatividad, idoneidad y accesibilidad. Un sujeto es considerado representativo cuando refleja de forma fidedigna las características del grupo de población más amplio al que pertenece, facilitando así la generalización de los resultados a otros colectivos con atributos similares en contextos diversos. Por su parte, la idoneidad hace alusión a la pertinencia de los participantes seleccionados con respecto al fenómeno que se pretende investigar. Finalmente, la accesibilidad se enfoca en evaluar la facilidad o dificultad para acceder a los registros y datos, considerando las limitaciones geográficas y temporales inherentes al estudio.

Enfrentar de forma efectiva un estudio sobre SHOs se encuentra condicionado por diversas variables, como las variaciones en las definiciones, el tamaño de las muestras, las fuentes de información y los protocolos de búsqueda de datos.

6.0 Grupo delincuente (Delincuentes de Homicidio en Serie)

Uno de los objetivos de este capítulo fue considerar explícitamente las regularidades en la toma de decisiones espaciales del asesino serial que no han recibido atención en la literatura hasta ahora.

El asesinato en serie es una forma violenta, extrema y relativamente rara de conducta delictiva humana (Allely et al., 2014; Hodgkinson et al., 2017). De hecho, el homicidio en serie es tan raro que se estima que representa menos del 1% de todos los homicidios, que involucra asesinatos múltiples por el mismo delincuente (Busch y Cavanaugh, 1986).

Los delitos seriales, que abarcan desde asesinatos hasta robos, son una realidad en todos los países. Pero entre todos, el asesinato en serie destaca por su gravedad. En la década de 1980, el FBI estableció que un asesinato en serie implicaba al menos tres homicidios separados en distintos lugares y momentos (Reid, 2017). Pero en 2008, esta definición se redujo a dos asesinatos. La falta de claridad en esta definición crea ambigüedades en la identificación de víctimas de asesinos seriales.

Según Turnbull et al. (2000), en EE.UU., estos delincuentes causan cerca de 800 muertes anuales. Woodworth y Porter (2002) estiman que hay al menos 35 asesinos en serie activos en el país. Hickey (2015) informó de 126 asesinos en serie identificados entre 2011 y 2013. Gurian (2017) señala que desde 1990, se sospecha de 660 individuos como asesinos en serie. Pero estas cifras muestran grandes discrepancias. La incertidumbre se debe, en parte, a víctimas que no se registran como tales, personas desaparecidas o grupos marginados, y aquellas cuyas muertes parecen naturales (Nichols, 2019). Si no se reconocen a estas víctimas, es imposible determinar el número exacto de asesinos en serie. Paul Holes menciona como una cifra aproximada, que alrededor de 2000 asesinos en serie no han sido detenidos en EE.UU. (Hamilton, 2022).

Aunque se ha debatido mucho sobre la definición exacta de asesinato en serie (Yaksic et al., 2019) todavía no hay consenso (Petee y Jarvis, 2000). La falta de claridad se agrava cuando se incluyen en la categoría a diferentes tipos de delincuentes, desde miembros del crimen organizado hasta profesionales de la salud que cometen homicidios, pasando por terroristas, sicarios y más

(Keeney y Heide, 1994). También se suman aquellos que perpetran delitos en el contexto del narcotráfico o médicos que prescriben medicamentos letales. Gurian (2017) expone que la falta de una definición clara complica aún más el cálculo de asesinos en serie existentes.

Yaksic et al. (2019), argumenta que los asesinos en serie y los delincuentes de homicidio en serie (SHO) ya no son lo suficientemente diferentes como para justificar una clasificación separada.

La definición actual de asesinato en serie respaldada por el FBI (Centro Nacional de Análisis de Delitos Violentos, 2008) identifica a un SHO como alguien que comete dos o más asesinatos, en casos separados, durante un periodo de tiempo. Aunque la búsqueda para lograr el equilibrio entre definiciones amplias y limitadas aún está en curso (Farrell et al. 2013), el consenso a menudo se basa en el "enfriamiento o período de inactividad", un término que lo abarca todo utilizado para denotar un supuesto volver a la normalidad durante los intervalos entre asesinatos. El "enfriamiento período" se utiliza teóricamente para separar a los SHO de otros asesinos que matan en respuesta a factores situacionales, conveniencia, supervivencia y resolución de conflictos y no como una característica importante de su estilo de vida (Aamodt et al., 2016). De los pocos intentos de mirar críticamente el enfriamiento fuera del período, Osborne y Salfati (2015) argumentan que estos intervalos son crucial para definir el homicidio en serie. Otros (Douglas et al., 1986; Yaksic, 2015) interpretar esta variable como un concepto desgastado retenido de una época en que se entendía acerca de los SHO dado que los asesinos en serie a menudo piensan acerca de matar durante períodos de inactividad y no se desconecta por completo del proceso de matar. El debate en torno a este aspecto de la definición de asesinato en serie está en curso y el concepto justifica más estudio.

6.1 Análisis de datos históricos de asesinos seriales.

La conceptualización de la delincuencia tiene sus raíces en los estudios del sociólogo Durkheim (1897), quien analizó las tasas de suicidio entre diferentes poblaciones como un indicador cuantitativo. A lo largo del siglo XX, la naturaleza y las fuentes de datos relacionados con el delito experimentaron transformaciones significativas. En la década de 1915, las estadísticas se basaban en registros de convicciones, factores ambientales y experiencias sociales para construir o verificar hipótesis sobre la inclinación hacia la conducta delictiva. Posteriormente, a partir de la década de 1950, la criminología experimentó un crecimiento en esfuerzos por cuantificar el delito, en gran parte impulsado por científicos sociales británicos que elaboraron teorías criminológicas (Dantzker y Hunter, 2011).

Durante los últimos cincuenta años, gran parte de lo que sabemos sobre los asesinos en serie proviene de fuentes secundarias, como entrevistas a delincuentes y estudios de casos. Si bien diversos investigadores han recopilado estos datos, muchos lo han hecho basándose en bases de datos propias, orientadas por sus intereses de investigación específicos. Esta fragmentación ha llevado a la prevalencia de evidencia anecdótica en discursos públicos sobre asesinos en serie. En la actualidad, una creciente "industria del asesinato en serie" perpetúa y magnifica estos mitos, posicionándolos como una forma de entretenimiento.

Los medios de comunicación han sido cómplices en solidificar estos mitos (Bohm, 1986; Robinson, 2000). Las investigaciones demuestran que la representación mediática influye de manera considerable en la percepción del público (Entman, 1989); debido a la amplia cobertura y

rapidez de los medios de comunicación para llegar a grandes segmentos de la población, estos mitos se difunden a una velocidad alarmante.

El género *true crime* ha dado lugar a una ola de investigadores que difunden información errónea. Godwin (2001) señala que los datos subyacentes al sistema de perfilado geográfico Dagnet (descrito en el capítulo 3) se extrajeron de revistas y libros del género *true crime*, fuentes que no siempre son confiables. Además, afirmó que el "*Missen Corpus of Serial Killer data*" se basó en fuentes predominantemente "anecdóticas", como revistas de detectives y literatura de crímenes reales.

El uso de fuentes periodísticas en la investigación de asesinatos en serie, aunque común, merece una cuidadosa consideración. Kathleen y Stephen (1991) sugiere que "los medios parecen ser la principal, si no la única, fuente para cuantificar los asesinatos en serie en los EE. UU.". Su estudio incluyó una revisión del índice de *The New York Times* desde enero de 1978 hasta junio de 1983, en busca de casos de asesinos en serie. Simonetti (1984) realizó un análisis similar, pero extendió su periodo desde enero de 1970 hasta noviembre de 1983.

Por su parte, Levin y Fox (1985) examinaron índices de seis importantes periódicos estadounidenses en busca de casos de asesinatos en serie y masivos que tuvieron al menos cuatro víctimas, entre 1974 y 1979. Hickey (1991), con un enfoque aún más amplio, rastreó casos de asesinatos en serie desde 1800 hasta 1995, usando diversas fuentes, desde periódicos y revistas hasta biografías y entrevistas. Sin embargo, siempre que se recurre a medios de comunicación como fuente principal, surge la inquietud sobre posibles sesgos en la información. Kiger (1990) subraya que las noticias pueden ser fuentes de datos problemáticas, ya que están sujetas a decisiones editoriales y a la posibilidad de sensacionalismo. Además, los medios pueden favorecer

casos especialmente escabrosos o aquellos que involucran a numerosas víctimas, especialmente si estas son afroamericanas (Jenkins, 1993) o perpetradas por delincuentes extranjeros.

En la década de 1970, Robert K. Ressler y John Douglas iniciaron la base de datos del *Violent Criminal Apprehension Program* (VICAP). Esta base fue reformulada en 1991 como *Violent Crime Linkage System* (VICLAS). Se trata de un sistema informatizado diseñado para identificar a delincuentes en serie a través de la correlación de información sobre crímenes. Esta herramienta permite que, desde cualquier jurisdicción, se puedan introducir datos estandarizados sobre asesinatos, facilitando así el análisis estadístico y la conexión de diversos crímenes que podrían ser atribuidos a un mismo delincuente.

La primera base de datos, conocida como el conjunto de datos de asesinos en serie del FBI, incluye información amplia sobre asesinos en serie, la mayoría de ellos de Norteamérica. Esta base de datos se origina en el Lexus/Nexus del FBI NCAVC, un recurso digital especializado en asesinatos seriales en EE. UU.

La información fue meticulosamente filtrada y verificada, descartando casos que se alinearan más con asesinatos masivos o episodios de violencia indiscriminada. Este proceso se realizó siguiendo la definición oficial del FBI sobre homicidio en serie. (Douglas et al., 1986). También se incluyeron asesinos en serie extranjeros conocidos (Rossmo, 1995).

El segundo conjunto proviene del “*Missen Corpus of Serial Killer*”, alojado en la Universidad de Liverpool, este repositorio contiene información recopilada de fuentes como periódicos, revistas e informes policiales sobre casos de alto perfil, lo que garantiza su credibilidad.

En 2010, Enzo Yaksic inició una base de datos, la *Serial Homicide Expertise and Information Sharing Collaborative* (SHEISC), con información detallada sobre 11.000 casos de homicidios en serie. En 2013, esta se fusionó con el Proyecto “*Radford/FGCU Serial Killer*”,

formando la base de datos no gubernamental más grande de su tipo, con más de 3.304 delincuentes y 9.000 perfiles de víctimas. Esta base, llamada *Consolidated Serial Homicide Offender Database* (CSHOD), provee datos valiosos para investigadores y ha sido utilizada parcialmente en esta tesis doctoral.

Kiger (1990) había señalado previamente las limitaciones de los datos existentes y abogó por la creación de nuevas fuentes basadas en datos empíricos. En respuesta a esta necesidad, se recopiló y consolidó la información de diversos investigadores para crear un registro completo y detallado. Gracias a su enfoque de acceso abierto, esta base de datos permite a los investigadores incrementar su fiabilidad y desmentir mitos sobre los asesinos en serie utilizando datos fidedignos y verificables (Yaksic, 2015).

Aamodt y Moyse (2003) investigaron extensamente bases de datos con el objetivo de identificar bibliografía (tanto publicados como en desarrollo) relacionados con asesinos en serie y crímenes violentos.

Varias universidades han desarrollado bases de datos con el propósito de proporcionar a estudiantes, investigadores, profesionales de medios de comunicación y personal de la administración pública información precisa sobre asesinos en serie. Por ejemplo, la *Florida Gulf Coast University* (Aamodt et al., 2020), cuenta con un proyecto de base de datos sobre asesinos en serie que incluye perfiles, enlaces a documentos judiciales, entrevistas, evaluaciones psicológicas y otros recursos relacionados. En este proyecto, se definió a los asesinos en serie como aquellos que cometieron homicidios de al menos dos personas en eventos separados, con un período de pausa o "enfriamiento" entre cada incidente, siguiendo la definición de Ressler y Shachtman (1992).

Radford/FGCU Serial Killer Database (Aamodt et al. 2020), se originó con la intención de consolidar información de acceso público en una sola plataforma, facilitando futuras investigaciones y la elaboración de estadísticas.

The Murder Accountability Project (Hargrove, 2021), fundado en 2015, es un colectivo multidisciplinario que busca enfatizar la importancia de llevar un registro preciso de los homicidios no resueltos en Estados Unidos.

A nivel europeo, es relevante mencionar la "Base de datos europea de asesinos en serie" o E.S.K.I.D.A.B. 2000 (De Luca, 2001) Esta base de datos lista a los asesinos en serie identificados en Europa hasta el año 2000, detallando las ciudades de actuación, periodos y tipos de víctimas.

The European Homicide Monitor (Liem et al., 2013) se inició como un proyecto financiado por la Unión Europea entre 2009 y 2011. Su objetivo era proporcionar un análisis epidemiológico de los homicidios ocurridos entre 2003 y 2006 en Finlandia, Países Bajos y Suecia.

6.2 Base de datos para Investigación

La realización de investigaciones sistemáticas sobre homicidios en serie se complica por las variaciones en la definición, el tamaño de la muestra, las fuentes de datos y los procedimientos de búsqueda.

Los investigadores más prominentes dentro del campo han construido grandes bases de datos de delitos en serie para usar en sus propias investigaciones bases de datos (Canter et al., 2000c; Godwin, 1999; LeBeau, 1987; Rossmo, 2000). Cada una de estas bases de datos se desarrolló con métodos específicos de integridad y ubicaciones de fuentes específicas.

Una dificultad principal, y potencialmente más grave, en investigaciones anteriores radica en la dependencia de bases de datos, frecuentemente creadas de forma adhoc, para el software que elabora perfiles geográficos. Estas bases se centran primordialmente en los datos empleados para evaluar la exactitud del software. En particular, los conjuntos de datos empleados para tales análisis suelen presentar problemas, como tamaños de muestra reducidos, una gama limitada de tipos de delitos y una selección de datos que no es aleatoria.

Por ejemplo, al evaluar la precisión del sistema CGT, Rossmo (2000) (véase capítulo 3) recurrió a datos de apenas 13 casos de asesinatos en serie, involucrando a 15 delincuentes seriales. Estos 13 casos se extrajeron de un conjunto de datos más amplio que contemplaba asesinos en serie responsables de al menos cinco víctimas posteriores a 1960, con residencia estable, que actuaban individualmente o con un solo cómplice, y que tenían patrones específicos de caza (Rossmo, 2000). Es importante señalar que estos datos no se derivaron de registros oficiales de la policía, sino de una base de datos accesible a través de plataformas en línea.

Dado su limitado tamaño y su enfoque especializado en ciertos tipos de delitos, este conjunto de datos presenta limitaciones significativas. Estas restricciones reducen considerablemente la diversidad de delitos y las circunstancias en las que se producen series delictivas, lo que afecta la capacidad de generalizar los resultados (Paulsen, 2006).

Canter et al. (2000), para evaluar la precisión del sistema Dragnet, utilizó una muestra específica y reducida de casos de asesinatos en serie. Analizando informes publicados sobre asesinos en serie estadounidenses condenados desde 1960, se logró compilar una lista detallada de estos delincuentes.

Con este método llegaron a una muestra de 79 delincuentes en serie que representaban un número no mencionado de víctimas. Para el estudio, se decidió utilizar la ubicación del sitio de eliminación de cadáveres más fácilmente disponible para una investigación de asesinato en serie.

De forma específica, tanto en el caso de (Rossmo, 2000) como de (Canter et al., 2000), los datos geográficos esenciales relacionados con los lugares del delito y las viviendas de los delincuentes no se obtuvieron de registros oficiales policiales. En su lugar, se basaron en informes de medios de comunicación, lo que suscitó interrogantes sobre la veracidad y precisión de los datos. Snook, Zito, et al. (2005), usaron una muestra notoriamente restringida, compuesta únicamente por 16 delincuentes, todos vinculados a robos en propiedades, y que habían cometido, al menos, diez delitos. Al emplear esta muestra, no se proporcionaron detalles sobre si su elección fue aleatoria, el motivo del enfoque exclusivo en robos a viviendas, o la razón para seleccionar delincuentes con un historial de numerosos delitos.

Por otro lado, Levine (2002), al evaluar la eficacia del software Crimestat, trabajó con una muestra que no se eligió al azar. En su lugar, se seleccionó con el propósito de equilibrar el número de incidentes perpetrados por cada delincuente.

Godwin (1999), desarrollo un conjunto de datos de asesinos en serie usando el 75% de los datos de *The Homicide Investigation Tracking System* (HITS) (Ferguson, 1987).

6.3 Set de datos

De acuerdo con las técnicas expuestas por Denzin y Lincoln, (1994), la triangulación de datos se empleó para fortalecer la integridad de la investigación, no solamente para validar la información ya existente, sino también con la esperanza de que los datos adicionales aportaran "una pieza más al rompecabezas" (Knafl y Breitmayer, 1991). El criterio de inclusión de los datos en este estudio se basó en la capacidad de acceder a diversas fuentes, lo que permitió realizar verificaciones cruzadas y validar la veracidad de los hechos presentados. Posteriormente, los datos recabados de distintas fuentes se contrastaron para determinar cuánto coincidían o diferían entre sí. Determinar el número exacto de víctimas resulta complicado, dada la dificultad de asociar delitos a un mismo delincuente y la fiabilidad cuestionable de las declaraciones.

Se establecieron criterios claros para la selección de casos, eligiendo escenarios de delitos que ya hubieran sido definidos previamente. Sin embargo, siempre hay potenciales amenazas a la validez, como la posibilidad de que ciertos detalles sobre los delincuentes, sus víctimas, o incluso casos enteros, nunca salgan a la luz o sean ocultados intencionalmente durante investigaciones en curso.

Es evidente que los datos presentan problemas. Puede haber errores en su registro, ya sea por incompetencia, negligencia o manipulación malintencionada. Las distorsiones pueden originarse por decisiones en la forma de presentar los informes, en el interés de proteger la privacidad de las familias de las víctimas o prevenir que lugares específicos se conviertan en atracciones para curiosos. Otra fuente de imprecisión surge de la incertidumbre sobre qué víctimas pertenecen realmente a un delincuente específico y dónde residía exactamente el delincuente en el

momento de la comisión del delito. A pesar de los esfuerzos por contrarrestar estas limitaciones, la integridad de los datos sigue siendo un desafío constante.

Por ejemplo Dahmer, Jeffrey Lionel se le imputaron 15 cargos de asesinato (Newton, 2006), en la investigación de Rossmo se contabilizan 17 asesinatos y se utilizaron en la investigación 10 (Rossmo, 2000), en la investigación de Lange se contabilizan 18 asesinatos (Lange, 1999), desde un punto de vista geográfico existen 6 localizaciones de los delitos, ya que 11 de los delitos se cometieron en el apartamento 213, Oxford, 924 North 25th Street, Milwaukee (Kerr, 2011). A pesar de estos desafíos, la investigación empírica sobre homicidios en serie es muy necesaria en un área dominada por estudios cualitativos.

Adjorlolo y Chan (2014) afirmaron que hay tres grupos de investigadores en el tema de los asesinatos en serie: los que prefieren guardar silencio sobre su definición; aquellos que confían en las demás definiciones o se refieren a casos conocidos de asesinatos en serie; y aquellos que proponen u operacionalizan el término para se adapten a su enfoque e interés de investigación, siendo este último el que mejor se adapta a la presente tesis doctoral.

6.4 Revisión sistemática de los datos preliminares

En la fase inicial de la búsqueda de datos sobre SHOs, contamos con la colaboración de estudiantes en prácticas del Centro Crimina de la Universidad Miguel Hernández de Elche. Para guiar esta tarea, se proporcionó un cuestionario específico, que se encuentra en el Anexo B.

Las directrices dadas a los estudiantes durante esta fase preliminar fueron las siguientes:

- 1) Dentro de la literatura, existen muchas definiciones de asesinos en serie, que generalmente difieren en cuanto a la cantidad de víctimas que un ofensor debe matar para ser considerado un asesino en serie. El número más común es un mínimo de tres víctimas (Holmes y Holmes, 1996). Sin embargo, algunos investigadores, como Jenkins (1993), usan cuatro o más como punto de corte.

Siguiendo la investigación de Fridel y Fox (2018), debido a que los delincuentes con cuatro o más víctimas son aceptados universalmente como asesinos en serie, el grupo de cuatro víctimas fue considerado por esta tesis doctoral como el mínimo de incidentes realizados por un SHO.

- 2) Osborne y Salfati (2015), argumentan que la fecha de inicio del delito resultará en cálculos más precisos de los intervalos de tiempo de homicidios en serie en lugar de utilizando la fecha en que se encontró el cadáver. Por tanto, el lugar donde el agresor se encontró por primera vez con la víctima es el de interés, y es el que se toma como base en esta búsqueda de datos.
- 3) Las estrategias de elaboración de perfiles geográficos deben probarse en condiciones que no son ideales (por ejemplo, con delincuentes viajeros), ya que estas son las condiciones que los perfiladores enfrentarán en las investigaciones reales. Solo de esta manera se pueden obtener medidas precisas de qué tan bien funciona una estrategia de elaboración de perfiles geográficos (Snook, Taylor, et al., 2005).

Es importante destacar que los nuevos métodos estadísticos suelen ser evaluados utilizando conjuntos de datos conocidos, en particular aquellos que han presentado

problemas en el pasado. Este proceso es un paso crucial para valorar la efectividad de una ecuación, algoritmo o función. De hecho, existen algunos conjuntos de datos reconocidos a nivel internacional, como el conjunto de datos de Longley, utilizado específicamente para probar funciones de regresión (Longley, 1967).

En el ámbito de la geografía delictiva, aún no contamos con conjuntos de datos estándar. No obstante, se hace evidente la necesidad de desarrollar dichos conjuntos de datos, considerando que serían de gran utilidad para la evaluación de futuras herramientas estadísticas. Esta iniciativa constituiría una aportación importante al campo, ya que posibilitaría la comparación de distintos métodos empleando los mismos conjuntos de datos, lo cual facilitaría una evaluación más homogénea y precisa (Levine, 2005).

- 4) El delincuente solo reside en un lugar: con esto, queremos decir que, aunque el delincuente puede cambiar de residencia, no se trasladará a un área completamente diferente y cometerá delitos allí (Morrow, 2010).

Después de asegurarse de que las directrices estuvieran claras y bien entendidas, se inició la fase de la búsqueda de SHOs. Para obtener esta información, se recurrió a fuentes diversas como sentencias judiciales, literatura científica rigurosa, bases de datos (Aamodt, M., et al., 2005; Aamodt et al., 2020; Hargrove, 2021) especializadas en asesinatos seriales.

Siguiendo las pautas propuestas por Berrie y Morrison (2013) la mayoría de las fuentes revisadas proporcionaron información detallada sobre los asesinatos. Se empleó un método retrospectivo, examinando las secciones de referencia para obtener más detalles.

En relación con la base de datos *Consolidated Serial Homicide Offender Database* (en adelante CSHOD), se accedió mediante un conjunto de datos (fichero Excel™) entregado por Enzo Yaksic⁴ (*Atypical Homicide Research Group, Boston, MA, USA*). El conjunto de datos proviene de la integración de registros de distintas bases de datos. Estas bases fueron creadas de forma independiente por diversas entidades: el Grupo de Investigación de Homicidios Atípicos y el Sistema de Seguimiento de Investigaciones de Homicidios de la Oficina del fiscal general del Estado de Washington.

Debido a que las variables espaciales no se incluyeron en el CSHOD, se buscaron información que permitiera la geocodificación⁵ de los lugares de los delitos de los SHOs. Por ejemplo, una búsqueda de la lista de referencias en Kerr (2011) reveló la existencia de veinticuatro casos con identificación espacial de la ubicación de los delitos. Repitiendo este proceso de recopilación de información hasta que se obtuvieron los datos adecuados para todos los SHOs.

Inicialmente, se compiló una muestra de 146 asesinos en serie de diversas regiones geográficas a nivel internacional. De estos, se seleccionaron 93, basándose en la abundancia de información accesible para los investigadores, para el análisis detallado (véase Anexo A). Para garantizar la precisión, cualquier información considerada para la investigación doctoral debía ser corroborada por, al menos, dos fuentes distintas.

⁴ <https://enzoyaksic.com/>

⁵ Se entiende por geocodificación aquel proceso por el que se transforma la descripción de una ubicación (unas coordenadas, o el nombre de una calle, por ejemplo) en entidades geográficas con atributos que se pueden emplear para la representación cartográfica o el análisis espacial.

Los datos de la tesis doctoral están disponibles para su acceso en el repositorio de Harvard Dataverse, una plataforma ampliamente reconocida por su integridad y accesibilidad en la comunidad académica. Los interesados pueden acceder a los datos mediante el siguiente link <https://doi.org/10.7910/DVN/U1CEPE> para revisar, replicar y construir sobre el trabajo realizado en la tesis doctoral, lo que fomenta la colaboración y el avance en la investigación.

6.5 Estudio descriptivo de la muestra

La muestra perteneciente a este estudio está formada por 93 SHOs y 608 eventos delictivos. Los ataques tuvieron lugar entre 1929 y 2017. El número mínimo y máximo de víctimas para esta muestra varió de 4 a 20. La mayoría (66,7%) de esta muestra tenía menos de 6 víctimas (tabla 6-1).

La mediana del número de víctimas fue 6, la serie más extensa incluyó 20 víctimas mientras que la serie más corta abarcó 4 víctimas. La duración media de una serie fue de 3 años.



Figura 6-1: Mapa descriptivo de la muestra.




Figura 6-2: Gráfico de barra de la variable país por SHO.




Figura 6-3: Frecuencia (autor por continente)




Figura 6-4: Gráfico de barras de la variable número mínimo eventos criminales por SHO

Tabla 6-1

Distribución de frecuencias de variable número mínimo eventos criminales por autor.

Serie criminal	Frecuencia	Porcentaje	% Acumulado
4	28	30,1	30,1
5	22	23,7	53,8
6	12	12,9	66,7
7	8	8,6	75,3
8	7	7,5	82,8
9	4	4,3	87,1
11	4	4,3	91,4
12	1	1,1	92,5
13	3	3,2	95,7
15	1	1,1	96,8
16	1	1,1	97,8
20	2	2,2	100,0




Figura 6-5: Frecuencia en series de delitos




Figura 6-6: Frecuencia (día semana) delito.

6.6 Variables

El objetivo de este capítulo fue determinar el grado en que ciertas variables espaciales encuentran apoyo empírico en el comportamiento de los diferentes tipos de SHOs que usan las

ubicaciones de primer contacto con la víctima. La presente investigación explorará los procesos de decisión geográfica al seleccionar un objetivo, las preferencias de direccionalidad, consistencia de destino y la coherencia de la distancia de los delincuentes de homicidio en serie.

Los criminólogos han desarrollado técnicas de elaboración de perfiles geográficos utilizando información obtenida de entrevistas con delincuentes identificados, con el objetivo de asistir a las autoridades en investigaciones de delitos en serie. Estas técnicas presuponen un comportamiento geográfico lógico por parte de los delincuentes, incluso cuando su comportamiento puede ser irracional. La escasa investigación sobre las diferencias de comportamiento geográfico entre delincuentes y no delincuentes pone en tela de juicio la eficacia de estas técnicas. En consecuencia, la elaboración de perfiles geográficos a menudo no alcanza una tasa de éxito notable, en parte debido a la multitud de variables que no se tienen en cuenta por los perfiladores geográficos (Phoenix, 2014).

6.7 Ficha de variables

Partiendo de la recogida de datos preliminar, se constituyó el instrumento de medida utilizado para esta investigación, realizado a partir de la literatura consultada teniendo en cuenta las variables más relevantes que pueden influir en el comportamiento de los agresores. Se ha utilizado el programa informático (BAIR Analytics Inc., 2014) *ATAC Workstation de Bair Software* (véase ANEXO B).

Las variables utilizadas en el presente estudio (tabla 6-2) se desarrollaron en base a investigaciones realizadas por (Beijsterveldt, 2006; Godwin, 2001; Goodwill et al., 2014; Kocsis, 2007; Kocsis y Irwin, 1997; Laukkanen y Santtila, 2006; Lundrigan y Czarnomski, 2006; Meaney,

2004; Paulsen, 2007; Snook et al., 2005; Warren et al., 1998), teniendo en cuenta las limitaciones y los factores que permiten el cálculo de un perfil geográfico efectivo, se han seleccionado un conjunto de variables relevantes que pueden influir en el comportamiento de los agresores, con la especificidad de centrarse únicamente en los elementos que podrían estar disponibles durante una investigación.

Tabla 6-2

Ficha de Variables

Variables	Descripción.
Variables Dependientes	
[30] Rango Criminal Círculo	[30] Merodeador (1) El punto de anclaje dentro del rango criminal definido por el círculo. Viajero (0) El punto de anclaje fuera del rango criminal definido por el círculo.
[36] Rango Criminal Envolverte Convexa	[36] Merodeador (1) El punto de anclaje dentro del rango criminal definido por la envolvente convexa. Viajero (0) El punto de anclaje fuera del rango criminal definido por la envolvente convexa.
[14] Rango Criminal Newton	[14] Merodeador (1) El punto de anclaje dentro del perfil superior. Viajero (0) El punto de anclaje fuera del perfil superior.
[16] Rango Criminal Elipse	[16] Merodeador (1) El punto de anclaje dentro de la elipse. Viajero (0) El punto de anclaje fuera de la elipse.
[27] Rango Criminal Venn	[27] Merodeador (1) El punto de anclaje dentro del área máxima superposición. Viajero (0) El punto de anclaje fuera del área máxima superposición.

Variables	Descripción.
[34]Rango Criminal CMD	[34] Merodeador (1) El punto de anclaje dentro del área de priorización del centroide aritmético. Viajero (0) El punto de anclaje fuera del área de priorización del centroide aritmético.
[38] Rango Criminal Box	[38] Merodeador (1) El punto de anclaje dentro del área del rectángulo delimitador mínimo. Viajero (0) El punto de anclaje fuera del área del rectángulo delimitador mínimo.

Variables Independientes	[]Descripción. (medida)
[1] Median Distance CMD/Crime	[1] La distancia mediana entre puntos (distancia mediana entre el centro de mínima distancia y el incidente delictivo). (metros)
[2] Average Distance CMD/Crimes	[2] La distancia media entre puntos (distancia media entre el centro de mínima distancia y el incidente delictivo). (metros)
[3] Max Distance CMD/Crimes	[3] La distancia máxima entre puntos (distancia máxima entre el centro de mínima distancia y el incidente delictivo). (metros)
[4]Min Distance CMD/Crimes	[4] La distancia mínima entre puntos (distancia mínima entre el centro de mínima distancia y el incidente delictivo). (metros)
[5] Spyder CMD/Crimes	[5] La distancia entre puntos (distancia entre el CMD y el incidente delictivo). (metros)
[6]Spyder Angle CMD /Crimes	[6] Ángulo entre puntos (distancia entre el centro de mínima distancia y el incidente delictivo). (grados decimales)
[7] Median Distance Centroide/Crimes	[7] La distancia mediana entre puntos (distancia mediana entre el centroide y el incidente delictivo) (metros)
[8] Average Distance Centroide/Crimes	[8] La distancia media entre puntos (distancia media entre el centroide y el incidente delictivo) (metros)
[9] Max Distance Centroide/Crimes	[9] La distancia máxima entre puntos (distancia máxima entre el centroide y el incidente delictivo). (metros)
[10] Min Distance Centroide/Crimes	[10] La distancia mínima entre puntos (distancia mínima entre el centroide y el incidente delictivo). (metros)
[11]Spyder Centroide /Crimes	[11] La distancia entre puntos (distancia entre el centroide y el incidente delictivo). (metros)

Variables	Descripción.
[12] Spyder Angle Centroid /Crimes	[12] Ángulo entre puntos (ángulos entre el centroide y el incidente delictivo). (grados decimales)
[13] Area Newton	[13] Área de la máxima superposición en el perfil superior. (metros ²)
[15] Area Elipse	[15] Área de la elipse. (metros ²)
[19] Mean Interpoint Distance	[19] La distancia media entre cada delito de la serie. (metros)
[20] Maximum Interpoint Distance	[20] La distancia máxima entre puntos (distancia máxima entre cada delito de la serie). (metros)
[21] Minimum Interpoint Distance	[21] La distancia mínima entre puntos (distancia mínima entre cada delito de la serie). (metros)
[22] Mean NN Dist.	[22] Distancia media observada de los incidentes. (metros)
[23] Expected Mean Dist.	[23] Distancia media esperada de los incidentes. (metros)
[24] NNI Valor	[24] Valor del índice del vecino más próximo. (clúster) si <1
[25] Distance Venn	[25] Distancia entre los dos puntos Venn más alejados de la serie. (metros)
[26] AreaVenn	[26] Área de la máxima superposición en diagrama Venn. (metros ²)
[29] Distance Canter	[29] Distancia entre los dos puntos más alejados de la serie. (metros)
[31] Area Canter	[31] Área del círculo basada en los dos crímenes más lejanos de la serie. (metros ²)
[32] Radio CMD	[32] Radio del área de priorización del centroide aritmético. (metros)
[33] Area CMD	[33] Área de priorización del centroide aritmético. (metros ²)
[35] Area of Convex Hull	[35] Área de un polígono envolvente convexa de los delitos de cada serie. (metros ²)
[37] Area Box	[37] Área del rectángulo que el cuadrado mínimo alrededor de los lugares de los delitos. (metros ²)
[39] CMD O'leary	[39] Centro de mínima distancia algoritmo O'leary
[40] Centroid O'leary	[40] Centroid de mínima distancia algoritmo O'leary

Variables	Descripción.
[41]Grado Intensidad	[41] Número total de delitos dividido por el total de días de toda la serie de delitos
[42] Intervalo días	[42] Número medio de días entre delitos
[43] Suma días	[43] Sumatorio de días en cada serie.
[44]Grado Regularidad	[44] El ritmo de cometer los delitos de los delincuentes, se aplica el coeficiente de variación en un número fijo de días entre los delitos.
[45] Median Distance anchor/Crime	[45] La distancia mediana entre puntos (distancia mediana entre el punro de anclaje y el incidente delictivo). (metros)
[46] Average Distance anchor/Crimes	[46] La distancia media entre puntos (distancia media entre el punto de anclaje y el incidente delictivo). (metros)
[47] Max Distance anchor/Crimes	[47] La distancia máxima entre puntos (distancia máxima entre el punto de anclaje y el incidente delictivo). (metros)
[48] Min Distance anchor/Crimes	[48] La distancia mínima entre puntos (distancia mínima entre el punto de anclaje y el incidente delictivo). (metros)
[49] Spyder anchor/Crimes	[49] La distancia entre puntos (distancia entre el punto de anclaje y el incidente delictivo). (metros)
[50] Spyder Angle anchor /Crimes	[50] Ángulo entre puntos (distancia entre el punto de anclaje y el incidente delictivo). (grados decimales)

6.8 Estudio Instrumental de caso

El estudio de casos es una herramienta esencial en las ciencias humanas y sociales, que permite una investigación profunda y sistemática de entidades sociales singulares. Esta metodología ofrece una perspectiva única para entender a fondo fenómenos criminológicos. Aunque se ha abordado desde un enfoque nomotético, su esencia se alinea más con la etnografía. La principal distinción con el método etnográfico radica en su objetivo: mientras que la etnografía se enfoca en describir culturas o comunidades, el estudio de casos busca entender el

funcionamiento interno de una entidad específica para formular hipótesis y explorar relaciones causales en un contexto y proceso determinados.

Para algunos expertos, el estudio de casos no es una metodología independiente, sino una estrategia de diseño investigativo que determina el objeto o sujeto de estudio y el entorno real en el que se desenvuelve. Guetterman y Fetters (2018) han descrito los estudios de caso como un enfoque "idílico", mientras que Yin (2014) sugiere que su principal objetivo es desentrañar y profundizar en la comprensión de un tema. En este enfoque, el propósito principal es arrojar luz sobre una cuestión teórica, utilizando el caso específico como medio para alcanzar objetivos más amplios en la investigación.

El propósito es analizar para obtener una mayor claridad sobre un tema o aspecto teórico (el caso concreto sería secundario). El caso es el instrumento para conseguir otros fines indagatorios en la investigación de la tesis doctoral.

6.8.1 Selección y definición del caso.

Se ha elegido analizar en profundidad el caso de Peter Sutcliffe, más conocido como "*The Yorkshire Ripper*". Este SHO está relacionado con, al menos, 20 hechos delictivos. La naturaleza y el alcance de sus delitos brindan un contexto profundo y rico para la investigación. Además, su trayectoria permite una exploración meticulosa de las intrincadas particularidades de la criminología en casos de asesinatos en serie. La cantidad de eventos criminales y el intervalo de tiempo entre ellos hacen que este caso requiera un examen minucioso y especializado.

Entre los años 1975 y 1980, fue dejando un rastro de terror por el norte de Inglaterra. Después de 9 ataques en los alrededores de las ciudades de Leeds y Bradford, dejó Wets Yorkshire

y cruzó los Pennines hasta llegar a Manchester, posteriormente, se movió de ciudad en ciudad sin cometer nunca un crimen dos veces seguidas en el mismo lugar.

6.8.2 Datos caso Peter Sutcliffe.

Sutcliffe, Peter Beattie, John (1981). *The Yorkshire Ripper*. London: Quartet/Daily Star. (ISBN 0-140-09614-0) Burn, Gordon (1990). *Somebody's husband, somebody's son*. NY: Penguin. (ISBN 0-434-09827-2) Cross, Roger. (1981). *The Yorkshire Ripper*. London: Granada. (ISBN 0-586-05526-6) Jones, Barbara (2002). *Evil beyond belief*. London: Blake Publishing (ISBN 1-903-40298-0) Jouve, Nicole (1986). *The street cleaner: The Yorkshire Ripper case on trial*. London: Marion Boyars (ISBN 0-714-52847-1). Yallop, David (1982). *Deliver us from evil*. NY: Coward, McCann. (ISBN 0-698-11113-3)

Tabla 6-3

Datos Peter Sutcliffe

Registro/ Serie	Fecha	Víctima	Ciudad	Latitud	Longitud
1	7/5/1975	ANNA ROGULSKYJ	KEIGHLEY	53.871481	-1.897633
2	8/15/1975	OLIVE SMELT	HALIFAX	53.734182	-1.864272
3	10/30/1975	WILMA McCANN	LEEDS	53.822352	-1.544942
4	1/20/1976	EMILY JACKSON	LEEDS	53.809052	-1.531635
5	5/9/1976	MARCELLA CLAXTON	LEEDS	53.836585	-1.503293
6	2/5/1977	IRENE RICHARDSON	LEEDS	53.833069	-1.499997
7	4/23/1977	PATRICIA ATKINSON	BRADFORD	53.810211	-1.767216
8	6/26/1977	JAINÉ McDONALD	LEEDS	53.818458	-1.535151
9	7/10/1977	MAUREEN LONG	BRADFORD	53.787368	-1.726811
10	10/1/1977	JEAN JORDAN	MANCHESTER	53.461321	-2.273241
11	12/14/1977	MARILYN MOORE	LEEDS	53.812352	-1.53960

12	1/21/1978	YVONNE PEARSON	BRADFORD	53.797916	-1.762342
13	1/31/1978	HELEN RYTKA	HUDDERSFIELD	53.649382	-1.779432
14	5/16/1978	VERA MILLWARD	MANCHESTER	53.453019	-2.257498
15	4/4/1979	JOSEPHINE WHITAKER	HALIFAX	53.713390	-1.874463
16	9/2/1979	BARBARA LEACH	BRADFORD	53.789796	-1.76127
17	8/18/1980	MARGUERITE WALLS	FARSLEY	53.80840	-1.672148
18	9/24/1980	APADHYA BANDAR	LEEDS	53.817419	-1.58065
19	11/5/1980	THERESA SYKES	HUDDERSFIELD	53.673159	-1.828876
20	11/17/1980	JACQUELINE HILL	LEEDS	53.823573	-1.579763

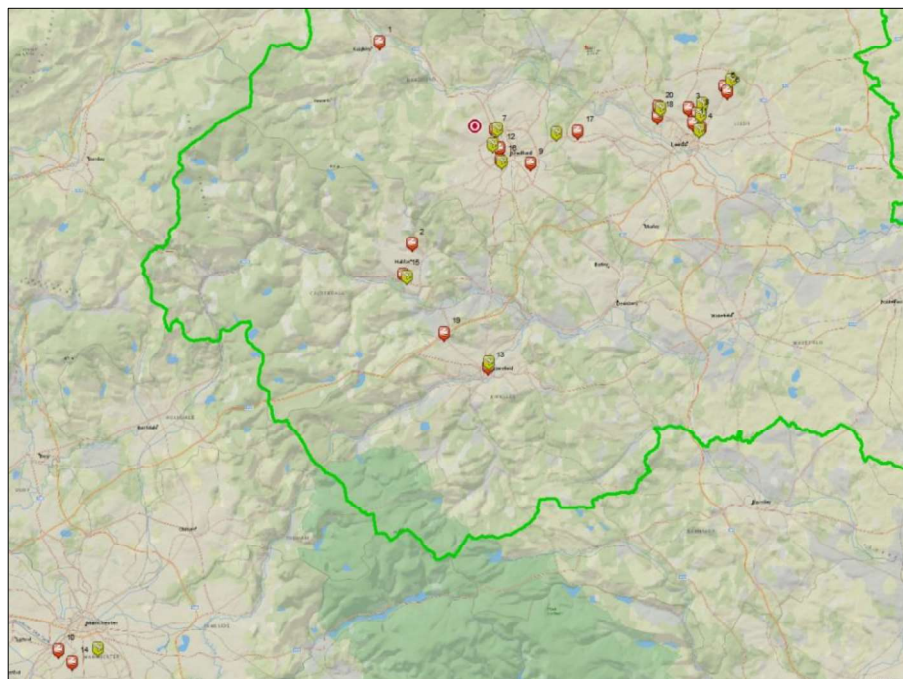


Figura 6-1: Estudio Instrumental de caso Peter Sutcliffe.
(Localizaciones de los eventos criminales en rojo).

Capítulo 7

OPTIMIZACIÓN PERFILADO GEOGRÁFICO (GEO-SCRIPT)

El desarrollo vertiginoso de la informática y las comunicaciones en las últimas décadas ha dado lugar a la creación de herramientas específicas que reflejan el conocimiento avanzado y el estado actual de diversas áreas del saber. Entre estos avances, los sistemas de información, y específicamente los SIG, destacan como ejemplares de esta evolución tecnológica (Buzai y Baxendale, 2015). Los SIG, al incluir aplicaciones de perfil geográfico, presentan una amplia gama de aplicaciones. Esta polivalencia surge, en parte, gracias a la representación de datos espaciales combinada con la integración de técnicas informáticas y matemáticas. Estas herramientas facilitan el análisis del comportamiento de delincuentes seriales dentro de un área geográfica específica.

Toda técnica de elaboración de perfiles geográficos parte de ciertas suposiciones sobre el comportamiento del delincuente. Una dificultad para comparar los diferentes enfoques radica en que estos supuestos no siempre son explícitamente claros.

Empezar con un modelo centrado en el comportamiento del delincuente convierte el reto de una visión criminológica a una orientación matemática. De hecho, si el modelo sobre el comportamiento delictivo es preciso, la tarea de elaborar perfiles geográficos se traduce en un problema estándar de estimación de parámetros estadísticos. En este marco, el parámetro esencial se identifica como la ubicación base o el punto focal del delincuente, tal como lo señala O'Leary (2009).

La investigación sobre las estrategias de elaboración de perfiles geográficos se puede dividir en dos categorías.

1. El primer tipo de investigación se ocupa de cómo las estrategias de elaboración de perfiles geográficos, implementadas por software, se desempeñan y pueden aplicarse a las investigaciones policiales.
2. El segundo tipo de investigación se ocupa de las propias estrategias de elaboración de perfiles geográficos.

Siempre que los investigadores tengan acceso al software de elaboración de perfiles geográficos, pueden probar hipótesis en la primera categoría. Sin embargo, solo los investigadores que han desarrollado sus propias aplicaciones pueden experimentar con estrategias de elaboración de perfiles geográficos (English, 2008).

El propósito principal de nuestra investigación radicó en consolidar y categorizar los modelos matemáticos existentes relacionados con la elaboración de perfiles geográficos, con el fin de diseñar una herramienta práctica que sirviera de soporte en investigaciones criminales. Si bien las herramientas preexistentes (descritas en el capítulo 3) han probado ser de gran valor, éstas se fundamentan principalmente en base a estrategias de probabilidad de distancia. No se evidencia cómo estas técnicas podrían adaptarse para incorporar información geográfica relevante que pueda influir en la elección de una escena del delito o en la determinación del domicilio de un delincuente.

Además, cada metodología existente para el perfilado geográfico (ya sea la estrategia de distribución espacial, de dispersión o de distancia de probabilidad) representa en esencia un modelo de comportamiento del delincuente en relación con un punto focal. Sin embargo, es ambiguo lo que estos modelos realmente proponen sobre el comportamiento delictivo en función de la atracción de los objetivos.

Por tanto, nuestra primera meta consistió en crear una herramienta más integrada para el perfilado geográfico. Dicha herramienta, desarrollada en forma de software, busca combinar lo mejor de las herramientas previas, manteniendo los parámetros de análisis accesibles para que los investigadores puedan evaluar cómo las variaciones en estos afectan los resultados. Es fundamental que esta herramienta deje en claro sus supuestos sobre el comportamiento delictivo, para que puedan ser analizados, discutidos y perfeccionados.

El segundo propósito del proyecto se orientó a materializar estas innovaciones matemáticas en una aplicación pragmática. El objetivo es presentar de forma estructurada, un conjunto de variables que puedan incidir en el comportamiento del delincuente, focalizándonos en aquellos elementos que serían de utilidad en el transcurso de una investigación en curso.

El código fuente de este software estará disponible bajo una licencia de código abierto apropiada para que otros investigadores y desarrolladores de herramientas puedan incorporar no solo el modelo sino también el código (véase ANEXO F y G). También es importante señalar que la idea detrás de nuestra investigación es encontrar una manera de extraer toda la información sobre la ubicación geográfica del punto de anclaje del delincuente a partir de una mínima información de cuatro incidentes delictivos, ocurridos en espacio y tiempo diferentes.

De hecho, queríamos estar seguros de que las técnicas matemáticas que se desarrollan eran más que simples construcciones teóricas, sino algo que tendría un impacto directo en la aplicación práctica (véase capítulo 12) al incorporar en WEB, la herramienta “GEO-SCRIPT” (Salafranca, 2023).

Tanto para la ciencia computacional como para la ciencia intensiva en datos, el ordenador pasa de ser una herramienta auxiliar a ser el auténtico protagonista de la investigación. Las nuevas técnicas de análisis de datos incluyen la modelización (Wainwright y Mugillan, 2004) o técnicas

estadísticas sofisticadas que, aprovechando las actuales capacidades de cómputo masivo, dejan de apoyarse en métodos paramétricos. Estos asumen que el análisis de unos pocos estadísticos, representativos de los datos, bastan para obtener conclusiones (Alonso Sarria et al., 2012). Con el nuevo enfoque, basado en modelos estadísticos que superan la regresión lineal (Zuur et al., 2009) o en métodos de aprendizaje automático (Kanevski et al., 2009), las conclusiones se obtienen con un análisis del conjunto de los datos. El analista delictivo deja de utilizar los algoritmos cerrados que acompañan a un determinado programa y comienza a crear sus propios algoritmos que resuelven problemas puntuales. Estos pueden ser listados más o menos estructurados de órdenes en programas modulares como GRASS o R (scripts) o programas escritos mediante lenguajes de alto nivel que acceden a librerías científicas especializadas. Estos algoritmos, y el código informático que los materializa, pasan a ser un elemento clave en la investigación de la criminología. Una de las ventajas más habitualmente mencionadas del software abierto es precisamente su modularidad, cualidad que permite modificarlo para adaptarlo a las necesidades específicas de cada proyecto o investigación (Cámara et al., 2012). Siendo una de las grandes potencialidades del software libre es el entorno que facilita el desarrollo y ejecución de scripts (Salafranca y Rodríguez, 2015).

Frente a la oferta de la gama en software comercial de perfil geográfico se está posicionando y cobrando cada vez con más fuerza el “Software Libre” u “Open Source (OS)”. En el caso concreto de los SIG esto representa una alternativa interesante debido especialmente al ahorro en el coste económico de obtención de licencias de explotación y uso de soluciones privadas y cerradas. Por tanto, las soluciones basadas en alternativas libres ofrecen un marco de trabajo accesible tanto a nivel usuario como profesional para organizaciones policiales y centros de

investigación criminal entre otros, permitiendo llevar a cabo distintos proyectos de investigación y desarrollo para la generación de conocimiento.

Uno de los aspectos más característicos del software libre es la naturaleza colaborativa entre comunidades de usuarios, lo que implica redes de desarrolladores trabajando desde distintas localizaciones, compartiendo código fuente para la mejora del software y el desarrollo de nuevas versiones.

Esta supone una dinámica distinta al modelo de desarrollo tradicional que se ha venido aplicando en el desarrollo de software basado en el mantenimiento en el control sobre el código fuente oculto, ejerciendo la explotación permanente del derecho de autor (Sanhouse, 2018) y de licencias privativas que hacen imposible el conocimiento y desarrollo del perfilado geográfico. Las preocupaciones por la importancia del código han llevado también a mirar con cierto recelo el código propietario. El software propietario no está libre de errores, pudiendo estar mal documentado internamente y poco probado (Barnes, 2010). Como alternativa, el software de código abierto, independientemente de su calidad original, acaba mejorando por las contribuciones de la comunidad científica y permite a otros compartir la línea de investigación del autor.

Por ello y como consecuencia de la necesidad de establecer nuevos modelos de cambio en la industria del software, se diseña, desarrolla y se prueba una nueva aplicación de creación de perfiles geográficos construida alrededor de cuatro principios básicos: simplicidad, velocidad, asequibilidad y precisión. El resultado fue GEO-SCRIPT (Salafranca ,2023), una aplicación de creación de perfiles geográficos basada en R y Phyton e implementada en el software QGIS. Ese prototipo tiene dos componentes: un motor de análisis que realiza los cálculos científicos de cada estrategia por cada serie, reportando un archivo *comma separated values* (.csv) de valores separados por comas, con todos los cálculos realizados en cada serie y una interfaz gráfica de

usuario, con los archivos en formato *shape* (.shp) para poder compartir y analizar en otra plataforma SIG los resultados obtenidos. Otro componente introducido es la evaluación de la eficacia (medidas de precisión) de la herramienta, es importante tener en cuenta que la eficacia tiene dos componentes: el primero es la frecuencia con la que el área de búsqueda contiene correctamente al delincuente y el segundo es el tamaño real de la región de búsqueda.

La herramienta GEO-SCRIPT permite explorar las capacidades predictivas de las redes neuronales en el contexto de *Circle Theory of Environmental Range* y *Convex Hull Polygon*, realizando una estimación para determinar si un SHO es viajero o merodeador en cada serie (véase capítulo 12).

Uno de los obstáculos identificados en la implementación de los algoritmos ha sido la lentitud de los procesos. Por ello, se hace imperativo explorar otros lenguajes de programación que permitan ejecutar los cálculos matemáticos de manera más ágil y eficiente.

7.0 Sistema de Información Geográfica (SIG) en el software QGIS

En esta tesis doctoral, se desarrolló una aplicación de código abierto de SIG en el software QGIS (QGIS Development Team, 2022) un proyecto de código abierto, que se inició en 2002 y se estableció en *Source Force* en junio de ese año. El objetivo inicial del proyecto QGIS era crear un visor de datos espaciales el cual fuera accesible para cualquiera que tuviera acceso a un ordenador. Hoy en día, QGIS ha llegado a un punto en su evolución en el que es utilizado por una amplia variedad de usuarios para tareas diarias de visualización, edición y análisis de datos espaciales, así como en criminología. El programa proporciona una interfaz amigable, además de funciones y características comunes, permite manejar formatos raster y vectoriales a través de las bibliotecas GDAL y OGR, así como bases de datos.

Se distribuye bajo la Licencia Pública General GNU (una colección de software libre; el acrónimo significa “GNU's not Unix”) Licencia Pública General (GPL), el desarrollo bajo esta licencia significa que se puede revisar y modificar el código fuente y garantiza que siempre se tendrá acceso a un programa de SIG que es libre de costo y puede ser libremente modificado, además permite la integración de plugins desarrollados tanto en C++ como en Python.

Se ha elegido trabajar sobre esta plataforma ya que proporciona facilidades a sus usuarios para la creación de *scripts* y *plugins*, y al ser de código abierto otros usuarios pueden hacer cambios sobre la funcionalidad de estos según las necesidades de cada necesidad organizativa.

7.1. Lenguaje de programación PYTHON y R

La automatización bajo el software QGIS se realiza utilizando el lenguaje de programación Python (Python Core Team, 2019), a través de una interfaz de programa de aplicación (API) Python, que se utiliza para expandir su funcionalidad y puede ayudar a explotar de manera eficiente las capacidades de un SIG.

Python es un lenguaje de programación interpretado, lo que significa que su ejecución se realiza a través de un intérprete. El objetivo de los desarrolladores de este lenguaje es mejorar la legibilidad de la sintaxis facilitando su uso a principiantes y usuarios con escasa o nula experiencia en programación, haciéndolo interesante para usos en investigación ya que usuarios de diversas disciplinas pueden acceder a crear sus propios script o programas con fines científicos y educativos Este efecto, un aumento número de contribuciones, ha sido muy notable desde la introducción de la API QGIS Python en QGIS 0.9 en 2007 cuando los nuevos desarrolladores comenzaron a agregar funcionalidad usando complementos de Python, hasta la versión PyQGIS 3.4 utilizada en (GEO-SCRIPT).

7.1.2 Integración R

Uno de los lenguajes más utilizados entre los científicos de datos para el análisis de datos es R, además R es un lenguaje y entorno de computación y gráficos estadísticos (R Core Team, 2020).

La integración de R con sistemas SIG amplía las capacidades estadísticas de R con numerosas herramientas de geoprocésamiento y manejo de datos disponibles en un SIG.

Al definir un SIG como un sistema para el análisis, manipulación y visualización de datos geográficos (Longley et al., 2011), se podría argumentar que R se ha convertido en un SIG (Bivand et al., 2013). En gran parte, esto se debe a paquetes que proporcionan clases espaciales y algoritmos codificados en R (a pesar de esto, estos paquetes también pueden vincularse a otro software fuera de R

El procesamiento integra R en QGIS, lo que permite a los usuarios ejecutar scripts de R desde dentro de QGIS y usar capas de QGIS como entradas.

La integración de R con sistemas de información geográfica (GIS) amplía las capacidades estadísticas de R con numerosas herramientas de geoprocésamiento y manejo de datos disponibles en un SIG. Esto y su API QGIS Python lo convierten en un candidato perfecto para el geoprocésamiento basado en consola. Al establecer una interfaz, el paquete R RQGIS hace posible usar QGIS como un caballo de batalla de geoprocésamiento desde dentro de R.

7.2 Desarrollo Complemento.

Un paradigma de programación es una forma de entender, concebir y aplicar determinados criterios en la construcción de una posible solución a un problema determinado (Schildt, 2002). El paradigma es aceptado por una comunidad de programadores y, sobre él, se han desarrollado lenguajes de programación que posibilitan su aplicación. Normalmente un paradigma de programación tiene una serie de formalismos matemáticos que le subyacen y que le permiten que, desde lo puramente formal, se pueda expresar el problema en condiciones que sea irrefutable en su descripción así su solución no siempre sea alcanzable bien por el lado matemático o bien por el lado computacional (van Roy, 2007).

Hay una similitud entre las metodologías propuestas para solucionar problemas matemáticos (Clements y Meredith, 1993; Melo, 2001) y las cuatro fases para solucionar problemas específicos de áreas diversas, mediante la programación de ordenadores (López, 2009).

Estas fases concuerdan con las operaciones mentales descritas por Polya (1957) para resolver problemas:

1. Analizar el problema (Entender el problema)
2. Diseñar un algoritmo (Trazar un plan)
3. Traducir el algoritmo a un lenguaje de programación (Ejecutar el plan)
4. Depurar el programa (Revisar)

Estas etapas coinciden parcialmente con los elementos generales que, según Schunk (1997), están presentes en todos los problemas:

1. Especificar claramente los resultados que se desean obtener (meta y submetas)
2. Identificar la información disponible (estado inicial)

3. Definir los procesos que llevan desde los datos disponibles hasta el resultado deseado (operaciones)

Para establecer un modelo más sólido en el diseño de la herramienta, debemos agregar dos temas a los elementos expuestos por Schunk (1997): formular el problema y determinar las restricciones.

La solución de un problema debe iniciar por determinar y comprender exactamente en qué consiste ese problema, en nuestro caso se inicia con la ficha de “Desarrollo con la formulación del problema”.

Precisar los resultados esperados (meta y submetas), para establecer los resultados que se esperan (meta) es necesario identificar la información relevante, ignorar los detalles sin importancia, entender los elementos del problema y activar el esquema correcto que permita comprenderlo en su totalidad (Woolfolk, 1999).

Identificar datos disponibles (estado inicial). Otro aspecto muy importante en la etapa de análisis del problema consiste en determinar cuál es la información disponible.

Establecer procesos (operaciones). Consiste en determinar los procesos que permiten llegar a los resultados esperados a partir de los datos disponibles.

En la medida de lo posible, es aconsejable dividir el problema original en otros más pequeños y fáciles de solucionar (submetas), hasta que los pasos para alcanzarlas se puedan determinar con bastante precisión (módulos). Esto es lo que en programación se denomina diseño descendente o *top-down* (Joyanes, 2001).

Después de un análisis profundo del problema y una vez comprendido en su totalidad, se inicia la fase de diseño de un algoritmo. Este actúa como un plan estructurado con pasos organizados en una secuencia lógica. Es esencial entender que solo después de haber analizado

detenidamente el problema, usando una metodología adecuada, es posible desarrollar dicho algoritmo.

Si bien los algoritmos se pueden expresar de muchas maneras, pero en esta investigación se tratarán de forma general como diagrama de flujo y de forma puntual como pseudocódigo. En pseudocódigo la secuencia de instrucciones se representa por medio de frases o proposiciones, mientras que en un diagrama de flujo se representa por medio de gráficos.

El diagrama de flujo es una representación gráfica de este algoritmo, utilizando símbolos geométricos para ilustrar la secuencia lógica de instrucciones. Estas instrucciones, a su vez, se traducirán a un lenguaje de programación, como Python, permitiendo su ejecución y prueba en un sistema informático.

7.2.1 Estructura de algoritmo en diagrama de flujo

En esta parte se presenta el procedimiento de creación del complemento de los scripts para QGIS (QGIS Development Team, 2022). Se detallan en las fichas (figura 7.2.1 a 7.2.9c) descripción de ficha, resultado algoritmo mediante mapa y los métodos utilizados para su implementación en diagramas de flujo (véase ANEXO J), mediante la herramienta Visustin (Salste, 2021) (solamente se ha incorporado una parte del diagrama de flujo debido a su extensión).

Un diagrama de flujo de datos emerge como una técnica altamente apropiada para representar de manera clara y precisa los procesos que constituyen un sistema de información. Este enfoque gráfico permite delimitar visualmente los confines del sistema y la lógica inherente a sus procesos, identificando las funciones que deben llevarse a cabo. Además, el diagrama de flujo de

datos visualiza el movimiento de los datos a través del sistema y las transformaciones que experimentan como resultado de la ejecución de los procesos.

Esta técnica implica la descomposición gradual de los procesos, partiendo desde un nivel general hasta alcanzar el detalle necesario para plasmar toda la semántica que el sistema en estudio requiere. El propósito fundamental del diagrama de flujo de datos radica en la creación de un modelo lógico de procesos que represente el sistema, prescindiendo de las limitaciones físicas del entorno. Este enfoque facilita significativamente la comprensión por parte de los usuarios y los miembros del equipo de desarrollo (Lopez-Garcia, 2008).

.

7.2.1 Introducción datos

Criterio clave para la inclusión de casos

Resultados esperados: Introducción de parámetros para realización del perfil geográfico

Formato de los datos entrada: El formato ESRI Shapefile (shp) es un formato de archivo informático de datos espaciales desarrollado por la compañía ESRI

Formato de los datos salida: (shp) (csv)

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos. El conjunto de datos consta de lo siguiente atributos:

- Descripción: es un campo de texto. contiene una breve descripción del delito.
- X: Es un campo geográfico. Da las coordenadas longitudinales del crimen.
- Y: Es un campo geográfico. Da las coordenadas latitudinales del crimen.
- Fecha: es un campo de fecha. Especifica la fecha exacta del crimen. Se creó un modelo de procesamiento de datos que permite ordenar las fechas de acuerdo con el momento de inicio serie, de esta manera se obtiene el primer punto en sentido cronológico en ser analizado para determinar si los puntos siguientes guardan alguna relación espacio temporal.
- IncidentNum: Es un campo numérico. Denota el número de incidente del delito. según el paso anterior. Puede coincidir con el número de fila de la table de atributos.

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes.

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclidiana)

Figura 7-1: [Ficha 1] Introducción datos

7.2.2 Cuadro de dialogo

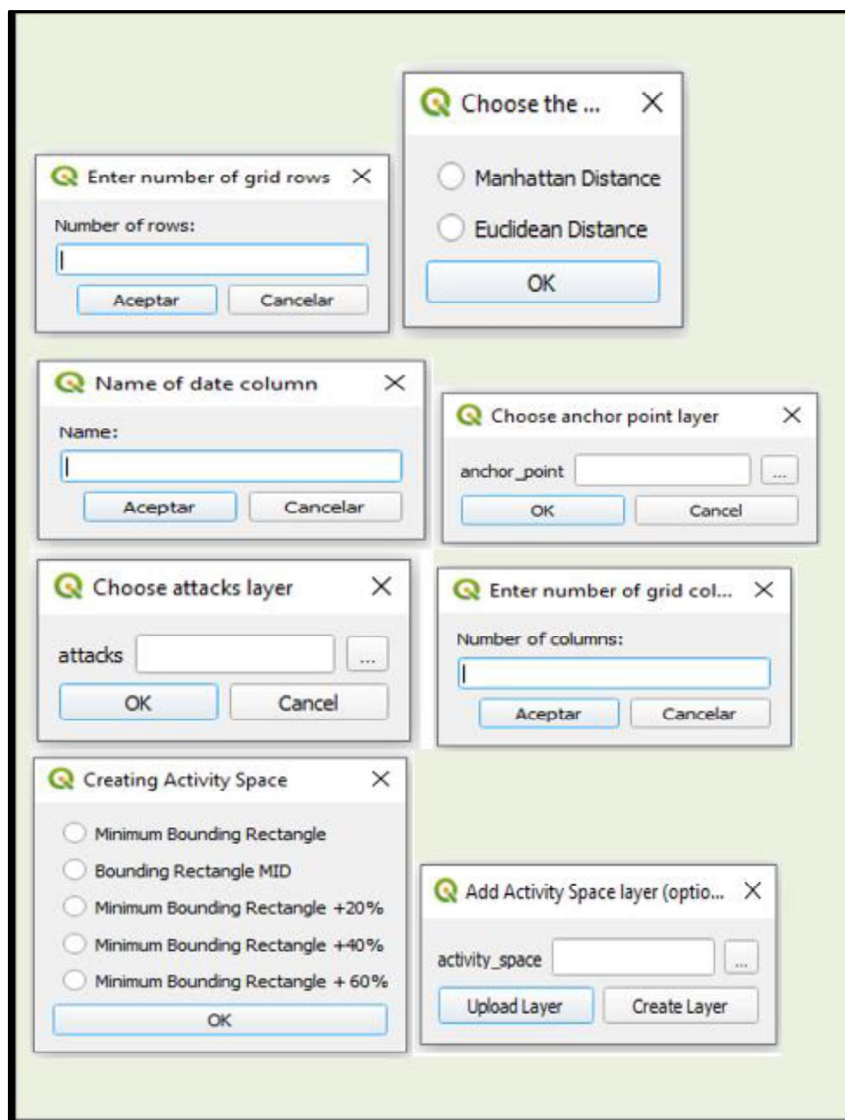


Figura 7-2: [Ficha 1a] Cuadro de dialogo de la herramienta "GEO-SCRIPT"

7.2.3. Transformación de coordenadas geográficas a proyectadas.

Análisis del Problema El SRC de origen de los datos es el WGS84 (*World Geodetic System 84*) o Sistema Geodésico Mundial 1984 es el sistema de referencia de coordenadas más extendido. El WGS84 es un sistema de coordenadas geográficas mundial que nos permite localizar cualquier punto sobre la superficie de la Tierra (sin que se requiera otro de referencia). El Sistema de Identificador de Referencia Espacial (SRID) continúa conociéndose como código EPSG (*European Petroleum Survey Group*), para el sistema SRC WGS84 corresponde el código EPSG 4326.

Formular el problema: La mayoría de los algoritmos para procesar datos espaciales funcionan correctamente cuando la información está proyectada en coordenadas planas, debido a que en los sistemas proyectados las coordenadas están expresadas en metros mientras que en los sistemas de coordenadas geográficas las coordenadas están expresadas en ángulo (grados).

Resultados esperados: Coordenadas proyectadas

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos, El conjunto de datos consta de lo siguiente atributos:

- Descripción: es un campo de texto. contiene una breve descripción del delito.
- X: Es un campo geográfico. Da las coordenadas longitudinales del crimen.
- Y: Es un campo geográfico. Da las coordenadas latitudinales del crimen

Restricciones: Las coordenadas introducidas deben ser geográficas.

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la longitud y latitud de atributos del set de datos.

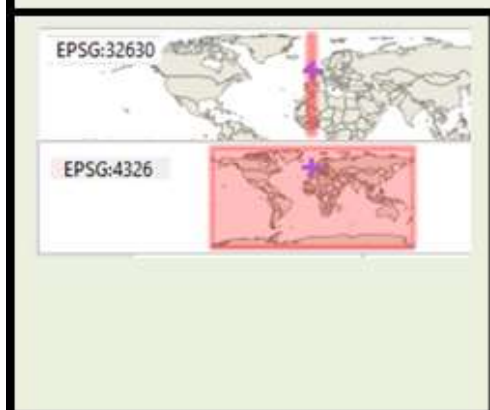


Figura 7-3: [Ficha 2] Transformación de coordenadas geográficas a proyectadas
Figura 7-4: Diagrama de flujo. Transformaciones coordenadas (véase ANEXO J).

7.2.4 Comprobación Merodeador / Viajero

Análisis del Problema Introducción de parámetros para comprobar el rango criminal [merodeador o viajero]

Formato de los datos entrada: El formato ESRI Shapefile (shp) es un formato de archivo informático de datos espaciales desarrollado por la compañía ESRI

Formato de los datos salida: (shp) (csv)

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos, El conjunto de datos consta de lo siguiente atributos:

- Descripción: es un campo de texto. contiene una breve descripción del delito.
- X: Es un campo geográfico. Da las coordenadas longitudinales del crimen.
- Y: Es un campo geográfico. Da las coordenadas latitudinales del crimen.

Formular el problema: Criterio clave para la inclusión de casos

Resultados esperados: Variables investigación: (1) Merodeador: define el área del círculo, dentro del cual contienen todos los eventos criminales del conjunto o zona en que el criminal ha desarrollado su ciclo asesino. (0) Viajero: no viven dentro del área. Viajan desde su base hacia otro lugar y es aquí donde establecen una zona de acción

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes.

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp.

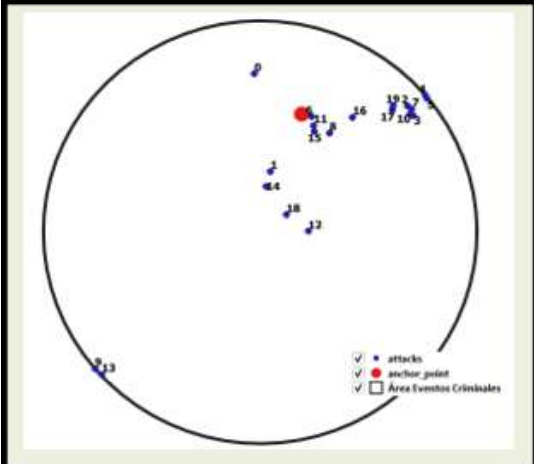


Figura 7-5: [Ficha 3] Comprobación merodeador o viajero.

Figura 7-6: Diagrama de Flujos. Comprobación merodeador o viajero (véase ANEXO J).

7.2.5. Estrategia distribución espacial (centro mínima distancia, centroide)

Análisis del Problema: Introducción de parámetros para el desarrollo de una estrategia de distribución espacial.

Formular el problema: Implementación del centroide y el algoritmo de Yehuda Vardi y Cun-Hui Zhang para el centro de mínima distancia (CMD).

Resultados esperados: Archivo en formato csv con distancias de la localización geográfica de cada incidente con el centro de mínima distancia, centroide y el punto de anclaje, respecto de cada secuencia. Se obtiene el grado relacionado con cada incidente desde el CMD y el centroide.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo I

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclidiana)

Resultado variables investigación: [1]; [2]; [3]; [4]; [6]; [7];[8]; [9]; [10]; [11]; [12]; [19]; [20]; [21]; [24];




Figura 7-7: [Ficha 4] Estrategia de distribución espacial.

Figura 7-8 : Diagrama de flujos. Implementación en QGIS del algoritmo de Yehuda Vardi y Cun-Hui Zhang para el centro de mínima distancia (véase ANEXO J).

7.2.6 Estrategia de distribución de dispersión (Diagrama de Venn)

Análisis del Problema: Una de las propiedades más útiles de los diagramas de Venn es su capacidad para visualizar relaciones binarias entre conjuntos. Dado que los delitos en serie están relacionados, es más probable que las áreas de superposición entre dos o más círculos incluyan la dirección del delincuente.

Formular el problema: Implementación de un diagrama de Venn, la intersección de dos conjuntos está representada por la región que está determinada por el interior de las curvas cerradas que dan forma a los conjuntos. La relación básica en teoría de conjuntos es la de pertenencia o no pertenencia a la que se les asignan valores 1 y 0, respectivamente, donde cuanto mayor es el valor, más pertenece un elemento al conjunto examinado.

Resultados esperados: Archivo en formato csv con distancias, áreas, zona de solapamiento y localización geográfica de cada incidente con respecto de cada secuencia.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo A

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, euclidiana)

Resultado variables investigación:[25];[26];[27]




Figura 7-9: [Ficha 5] Diagrama de Venn.

Figura 7-11: Diagrama de flujos. Estrategia de distribución de dispersión (véase ANEXO J).

7.2.7 Estrategia de distribución de dispersión (Círculo de Canter)

Análisis del Problema En su representación más simple, el patrón físico del movimiento del delincuente puede concebirse como un círculo que abarca la ubicación del hogar en el centro. El radio del círculo es representativo de la distancia entre la base de operaciones del delincuente y el sitio del delito más alejado.

Formular el problema: Un problema adicional es que en una serie criminal un delincuente puede ser clasificado como un viajero, pero en el momento siguiente, después de otro crimen, como un merodeador

Resultados esperados: Archivo en formato csv con distancias y localización geográfica de cada incidente con el centro del círculo y el punto de anclaje, respecto de cada secuencia.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo I

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclidea)

Resultado variables investigación:[29];[31];[30]




Figura 7-10: [Ficha 6] Estrategia de distribución de dispersión.

Figura 7-11 :Diagrama de flujos. Estrategia de distribución de dispersión (Círculo de Canter) (véase ANEXO J).

7.2.8 Estrategia de distribución de dispersión (Círculo centro mínima distancia)

Análisis del Problema: El desglose del cuadrante es particularmente útil para la interpretación, proporciona un porcentaje de delitos que ocurrieron dentro de cada uno de los cuatro cuadrantes centrados en el CMD. Este desglose de cuadrante se usa para ayudar a priorizar y reducir el área del perfil.

Formular el problema: Implementación del algoritmo de Priorización el Centroide Aritmético.

Resultados esperados: Archivo en formato csv con distancias, áreas y ángulo de cada incidente con el centro de mínima distancia y el punto de anclaje, respecto de cada secuencia.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo I

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclideana)

Resultado variables investigación: [32]; [33];[34]




Figura 7-12: [Ficha 7] Estrategia de distribución de dispersión (Priorización del Centroide Aritmético).

Figura 7-13: Diagrama de flujos. Estrategia de distribución de dispersión (Priorización del Centroide Aritmético) (véase ANEXO J).

7.2.9 Estrategia de distribución de dispersión (Rectángulo área mínima limitación)

Análisis del Problema: El rectángulo delimitador mínimo es el rectángulo de menor área que cubre todos los puntos de un conjunto.

Formular el problema: El método más sencillo para encontrar el rectángulo delimitador mínimo implica recorrer los bordes del polígono convexo. Para cada uno de estos bordes, se determina el rectángulo delimitador más ajustado que comparte un lado con dicho borde del polígono. De estos rectángulos generados, se selecciona aquel con área más reducida

Resultados esperados: Archivo en formato csv con distancias de localización geográfica de cada incidente con el centro de mínima distancia, centroide y el punto de anclaje, respecto de cada secuencia.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo A

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclideana)

Resultado variables investigación: [37];[38]

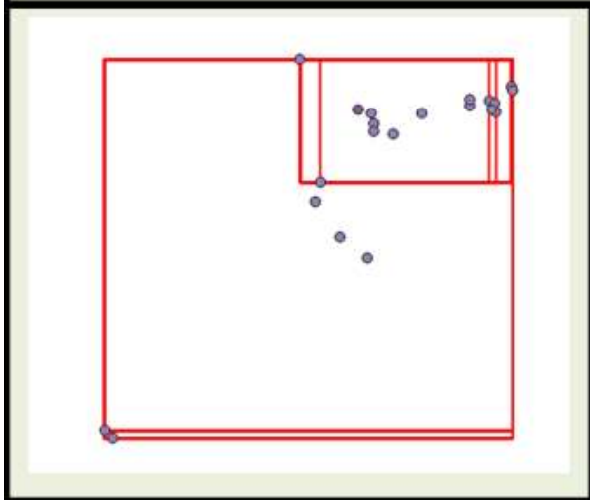


Figura 7-14: [Ficha 8] Estrategia de distribución de dispersión.

Figura 7-15: Diagrama de flujos. Estrategia de distribución de dispersión (Rectángulo mínima delimitación) (véase ANEXO J).

7.2.9a Estrategia de distribución de dispersión (Envolvente convexa)

Análisis del Problema: La envolvente es crucial al determinar el área dentro de la cual se puede predecir el comportamiento de una variable basándonos en muestras específicas.

Formular el problema: Los valores estimados dentro de la envolvente son el resultado de una interpolación.

Resultados esperados: Archivo en formato csv con distancias y áreas de las envolventes convexas en cada serie.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo I

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclídeana)

Resultado variables investigación: [35];[36]




Figura 7-16: [Ficha 9] Estrategia de distribución de dispersión.

Figura 7-17: Diagrama de flujos. Estrategia de distribución de dispersión (Envolvente convexa.) (véase ANEXO J).

7.2.9b Estrategia de distribución de dispersión (Newton-Swoope)

Análisis del Problema: Se incorpora algoritmo *Weiszfeld* aplicado al modelo de Newton-Swoope, que ha introducido medidas robustas que el centro medio, para centrar datos en presencia de valores atípicos.

Formular el problema: Implementación del modelo Newton-Swoope con el centro medio y el centro de mínima distancia

Resultados esperados: Archivo en formato csv con distancias y áreas de máxima superposición del perfil superior.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo A

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclideana)

Resultado variables investigación: [13];[14]




Figura 7-18: [Ficha10] Estrategia de distribución de dispersión

Figura 7-19 Diagrama de flujos. Estrategia de distribución (Newton-Swoope) (véase ANEXO J).

7.2.9c Estrategia de distribución de dispersión (Elipse)

Análisis del Problema: La elipse de desviación estándar puede explicar mejor las irregularidades en el paisaje.

Formular el problema: La elipse es capaz de identificar el centro de una distribución, así como la dispersión como la dirección de la de la dispersión.

Resultados esperados: Archivo en formato csv con.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo A

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes.

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclideana).

Resultado variables investigación: [15];[16]




Figura 7-20: [Ficha 11] Estrategia de distribución de dispersión (Elipse)

Figura 7-21 Diagrama de flujos. Estrategia de distribución de dispersión (Elipse) (véase ANEXO J).

7.2.9d Estrategia de distancia de probabilidad

Análisis del Problema: Ofrecen una táctica de búsqueda estructurada que representa una ventaja destacable frente a las estrategias basadas en distribución espacial

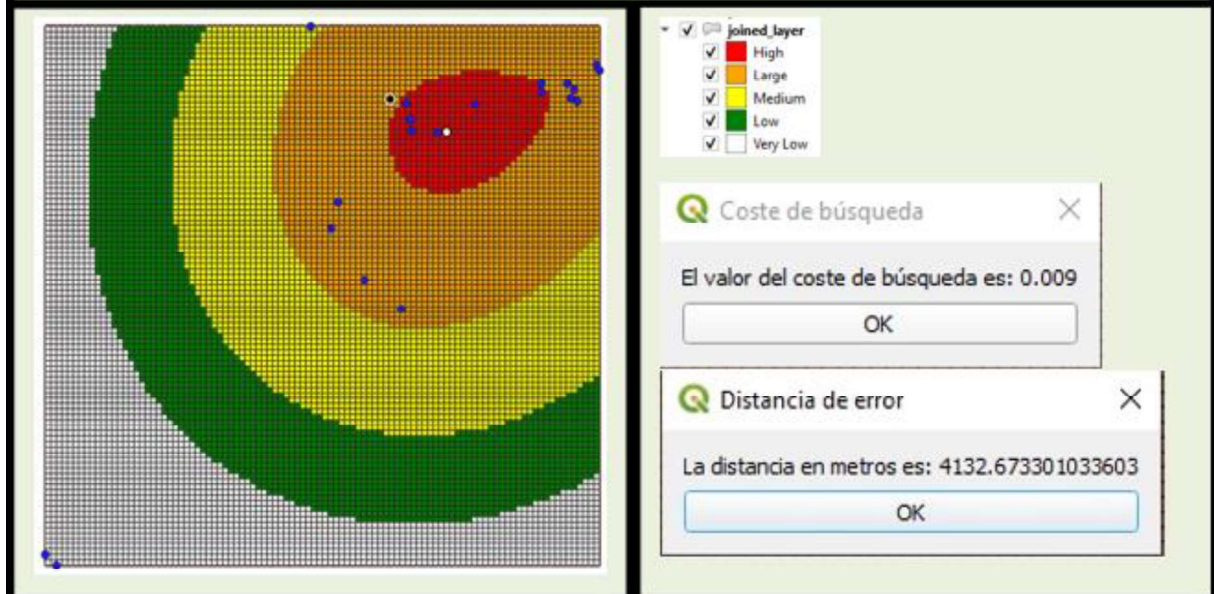
Formular el problema: Las Estrategias de Probabilidad de Distancia también conocidas como estimaciones de *journey to crime* generan un perfil geográfico que comúnmente se visualiza en un mapa. La prominencia del perfil refleja la probabilidad de hallar el punto de anclaje en una ubicación específica

Resultados esperados: Archivo en formato csv y shp con diversas funciones de decaimiento y distancias de error del perfil.

Datos disponibles: Los datos utilizados en este proyecto de investigación son el conjunto de datos del Anexo A

Restricciones: Cada uno de los casos introducidos debe contener un mínimo de cuatro incidentes. Las coordenadas introducidas deben ser geográficas. Si dos valores de la fecha se encuentran duplicados, comprueba si la longitud y latitud coinciden para esos incidentes.

Procesos necesarios: Introducción de incidentes en formato shp. Solicita el nombre de la columna que contiene la fecha de la tabla de atributos del set de datos. Introducir el punto de anclaje (domicilio) en formato shp. Determinar el área de actividad del perfil (elección de 5 áreas predeterminadas o introducción de una por usuario). Determinar el número de filas y columnas del área seleccionada. Solicitud de la métrica del perfil (Manhattan, Euclideana)



The figure shows a GIS interface with a map on the left and two dialog boxes on the right. The map displays a probability distance map with concentric rings of color (red, orange, yellow, green) representing probability levels. The 'Coste de búsqueda' dialog shows a value of 0.009. The 'Distancia de error' dialog shows a distance of 4132.673301033603 meters.

Figura 7-22. [Ficha 12] Estrategia de distancia de probabilidad

Figura 7-23 Diagrama de flujos. Estrategia de distancia de probabilidad (véase ANEXO J).

PARTE III ESTUDIO EMPÍRICO II [PROCEDIMIENTO]

Capítulo 8

HUMANOS VERSUS ALGORITMOS: DIFERENCIAS EN LA EFICACIA EN LA PERFILACIÓN GEOGRÁFICA CRIMINAL.

Este capítulo se ha publicado como:

Salafranca Barreda, D. (2023). Humanos versus Algoritmos: Diferencias en la eficacia en la perfilación geográfica criminal. *Revista Española De Investigación Criminológica*, 21(1), e797. <https://doi.org/10.46381/reic.v21i1.797>

Indicio de calidad de la tesis doctoral (Artículo Científico) véase ANEXO C

Resumen

Los estudios que han explorado una variedad de tareas de predicción han demostrado que las heurísticas utilizadas por los individuos para simplificar problemas complejos pueden funcionar con la misma precisión que las técnicas actuariales. Con el objetivo de comprobar esta hipótesis, se llevó a cabo un experimento para investigar si las ventajas de la práctica humana en la elaboración de perfiles geográficos coinciden con las ventajas de utilizar algoritmos informáticos. Hasta el momento, en España no se han encontrado estudios que aborden el debate en curso sobre si las personas pueden ser igual de efectivas que las técnicas informáticas actuariales al tomar decisiones sobre la localización del domicilio de un delincuente en serie. La presente investigación, realizada en dos centros universitarios españoles, es la primera en abordar esta cuestión. Utilizando una muestra aleatoria de delincuentes en serie, los resultados indicaron que los participantes a los

que se les presentó una heurística basada en la hipótesis del círculo y una estrategia de decaimiento de la distancia no mostraron una mejora significativa en la precisión de las predicciones, y su desempeño posterior al entrenamiento no difirió significativamente de las predicciones generadas por una técnica actuarial. Se discuten varias posibles explicaciones para las actuaciones precisas de los participantes y las implicaciones prácticas para la integración de habilidades cognitivas.

Capítulo 9

EVALUACIÓN DE LAS ESTRATEGIAS DE DISPERSIÓN UTILIZADAS PARA LOCALIZAR A LOS DELINCUENTES DE HOMICIDIOS EN SERIE.

Este capítulo se ha publicado como:

Salafranca Barreda, D., Yaksic, E. Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders. *Journal Police Criminal Psychology* (2022).
<https://doi.org/10.1007/s11896-022-09561-3>

Indicio de calidad de la tesis doctoral (Artículo Científico) véase ANEXO D

Resumen

El análisis espacial ha sido desde hace mucho tiempo una herramienta valiosa dentro del proceso de investigación criminal. El objetivo de la presente investigación es analizar tres estrategias de distribución de dispersión y construir un modelo de perfil geográfico basado en la teoría de conjuntos que pueda determinar un área de referencia donde pueda comenzar la búsqueda del punto de anclaje de un delincuente homicida en serie (SHO). En el presente estudio, se probaron modelos de perfiles circulares con distancia variable y elípticos generados para 84 SHOs. En general, el estudio encontró que el modelo elíptico tuvo un mejor desempeño que los modelos circulares, probablemente debido al área más grande de las elipses. Al considerar fines de utilidad policial, los modelos circulares pueden ser más eficientes. Se discuten las implicaciones y las direcciones para futuras investigaciones.

Capítulo 10

LA APLICACIÓN DEL PERFIL GEOGRÁFICO DE NEWTON Y SWOOPE.

Este capítulo se ha publicado como:

Salafranca Barreda, D. (2021), The application of Newton and Swoope's geographical profile to serial killers. *J Investig Psychol Offender Profil*, 2021;18:68-78. <https://doi.org/10.1002/jip.1566>

Indicio de calidad de la tesis doctoral (Artículo Científico) véase ANEXO E

Resumen

Muy posiblemente la primera aplicación del análisis geográfico para identificar y caracterizar el comportamiento espacial del delincuente con respecto a la escena del crimen fue desarrollada en 1980 por Milton Newton. Aunque estudios previos han utilizado el proceso geoforense de Newton y Swoope (Kent, 2009; Leitner et al., 2007) para verificar la efectividad del algoritmo, no hay, hasta donde sabemos, investigaciones que hayan validado el procedimiento con casos de asesinatos en serie. El objetivo principal del estudio es analizar una muestra de 41 delincuentes de homicidios en serie (SHOs), con un número mínimo de seis crímenes y evaluar el método propuesto por Newton (1988). Los resultados confirman solo la primera suposición de Newton en la que después del quinto crimen de la serie, el "refugio" estimado está cerca del "refugio" real, descartando que el área de búsqueda se vuelva progresivamente más pequeña y que el "refugio" se encuentre en el área de búsqueda.

Capítulo 11

MODIFICACIÓN DEL ALGORITMO DEL MÉTODO DE ANÁLISIS GEOFORENSE DE NEWTON Y SWOOPE.

Resumen

En el ámbito geoforense, la metodología propuesta por Newton y Swoope tiene sus fundamentos en la estadística descriptiva, centrándose particularmente en el concepto del centro medio. A pesar de su relevancia, este enfoque se muestra sensible ante valores espaciales atípicos, lo que podría debilitar su rendimiento en aplicaciones prácticas. Con miras a refinar y potenciar su exactitud, sugerimos una modificación de la ecuación original, incorporando el algoritmo de Weiszfeld, reconocido por su robustez ante dichas anomalías. Esta investigación tiene como objetivo cotejar el centro medio del modelo geoforense de Newton (1988) con un enfoque ajustado en el centro de mínima distancia. Este último se aplica a una muestra de 10 delincuentes en homicidios en serie (SHOs), cada uno asociado a un mínimo de cinco incidencias delictivas. Mediante la comparación entre la residencia estimada (perfil superior) y la residencia real del SHO, buscamos discernir la eficacia y confiabilidad del modelo del centro de distancia mínima.

Introducción

A mediados de la década de 1980, el geógrafo de la Universidad Estatal de Louisiana, el Dr. Milton Newton, desarrolló el método "geoforense" para el análisis geográfico del delito. Hoy en día, se considera una de las primeras técnicas de perfilado geográfico, que tiene como objetivo

identificar y caracterizar el comportamiento espacial del delincuente con respecto a la escena del crimen (Newton y Swoope 1987). El fundamento del enfoque "geoforenses" se asienta en dos pilares teóricos: la teoría de la actividad cotidiana de Cohen y Felson (1979) y la teoría de la elección racional de Cornish y Clarke (1986). Ambas perspectivas se centran en el comportamiento de los delincuentes en la elección de sus objetivos (véase capítulo 1).

Desafortunadamente, las referencias explicativas al método "geoforenses" se basan en un manuscrito (inédito) que detalla los principios metodológicos y teóricos del proceso geoforenses (Newton y Swoope 1987), en una presentación en la reunión anual de 1987 de la Academia Americana de Ciencias Forenses (AAFS), San Diego, CA (Newton y Swoope 1987) y en un manuscrito que explica los fundamentos teóricos y metodológicos del proceso geoforenses (Newton, 1988).

Newton y Swoope (1987) sugieren una clasificación de los delincuentes en series en dos categorías principales: "móviles", aquellos geográficamente itinerantes, y "estáticos", los que se mantienen geográficamente estables. Los primeros delinquen en extensas áreas que trascienden fronteras tanto culturales como psicológicas. Un rasgo distintivo es que su "zona de caza" no tiene un centro claramente definido desde el cual operan, como indica Rossmo (2000). En contraposición, los delincuentes estáticos actúan en un territorio limitado, generalmente circunscrito por barreras mentales y particularidades geográficas. Estos delincuentes actúan dentro de su zona de seguridad, moviéndose entre puntos específicos de actividad. Es común que posean un lugar central o "refugio" desde el que operan. Tales patrones han sido documentados en múltiples estudios (Canter y Larkin, 1993; Hickey, 1991; Holmes y Holmes, 1998). Rossmo (2000) destaca que la base de un perfil geográfico supone que el "refugio" del delincuente está dentro del

rango de sus delitos. Por lo tanto, entender su movilidad es esencial para crear perfiles geográficos precisos.

El método de análisis geoforenses se utiliza para determinar la ubicación más probable del punto de anclaje o refugio de un delincuente (geográficamente estático). La técnica permite la determinación de un área de búsqueda centrada en el punto de anclaje.

El algoritmo ideado por Newton y Swoope (1987) incorpora técnicas fundamentales de estadística descriptiva, centrándose especialmente en el cálculo del centro medio. Estas estrategias han demostrado ser eficaces en la creación de perfiles geoforenses, especialmente en situaciones donde las escenas del delito están geográficamente cercanas. Bajo tales circunstancias, el centro medio suele alinearse con notable precisión al punto de anclaje real del delincuente (van Der Kemp, 2014). Sin embargo, cuando una serie de delito presenta una ubicación que se desvía considerablemente de los demás, es decir, un valor atípico, dicho valor afectará de manera significativa el cálculo del centro medio, desplazándolo en dirección al valor atípico. En tales situaciones, el centro medio no ofrece una representación fiable del verdadero punto de anclaje del delincuente.

En el ámbito criminológico, es común encontrar valores atípicos o "*outliers*" en el análisis de datos espaciales. Estos valores se apartan significativamente de la mayoría y no siguen el patrón general de la distribución de datos. Aunque existen múltiples definiciones y métodos propuestos para identificar y tratar estos valores, hay un debate sobre si se deben eliminar o no. La eliminación de estos valores atípicos puede alterar las conclusiones extraídas y, a veces, resultar en la pérdida de información valiosa. Por ello, es esencial comprender la causa y el impacto de estos valores antes de decidir su inclusión o exclusión en el análisis.

Una cuestión que surge de manera natural es: ¿Cómo debemos manejar estos valores atípicos? Simplemente ignorarlos podría no ser la estrategia más certera, especialmente si buscamos comprender la razón detrás de dichos valores. Es innegable que pueden distorsionar los resultados de un análisis, por lo que es esencial identificarlos y abordarlos de manera apropiada.

Rossmo et al. (2005), señalan que los valores atípicos pueden complicar la elaboración de perfiles geográficos, ya que pueden influir de manera desproporcionada en el perfil resultante. A pesar de que en pequeñas cantidades pueden ser tolerables, es aconsejable identificar y, si es necesario, descartar estos valores. A menudo, estos valores atípicos resultan ser errores o reflejan comportamientos realmente inusuales, como un desplazamiento poco común del sospechoso. En tales casos, se sugiere llevar a cabo análisis detallados para determinar su relevancia y veracidad.

Aunque estudios previos han adaptado el proceso geoforenses de Newton-Swoope (Kent y Leitner, 2007), modificando el cálculo del área de búsqueda (de forma circular) al modelo elíptico, en el siguiente estudio se propone la modificación de la ecuación de Newton-Swoope aplicando el algoritmo de *Weiszfeld*, para mejorar la robustez de los datos en presencia de valores atípicos.

El objetivo principal del estudio es analizar el centro medio del método geoforenses presentado por Newton (1988) y evaluar el método propuesto utilizando el algoritmo de *Weiszfeld*.

Para ello, se analizarán y evaluarán tres condiciones de la metodología:

1. El refugio o punto de anclaje estimado se acerca al real con cada serie delictiva sucesiva después del quinto delito de la serie.
2. El área de búsqueda se hace más pequeña con cada delito sucesivo después del quinto delito.
3. El punto de anclaje real cae dentro del área de búsqueda después de la quinta serie.

Estrategias de perfil geográfico

La investigación moderna en el campo criminológico ha evolucionado de manera significativa gracias al avance tecnológico. Esto implica la habilidad de construir modelos aptos para evaluar hipótesis relacionadas con los parámetros en estudio. En este contexto, los investigadores no sólo recopilan evidencia tangible, sino que también se apoyan en herramientas digitales y técnicas analíticas avanzadas. Un ejemplo de este avance es cómo los expertos han utilizado las tecnologías para diseñar modelos en los que la información sobre las escenas del delito podría usarse para localizar el hogar de un delincuente. Estos modelos, al integrar variables como patrones de movimiento, tiempos y lugares de los incidentes, ofrecen una nueva perspectiva en la resolución de casos y en la identificación de posibles sospechosos. Es una muestra palpable de cómo la combinación de habilidades analíticas y tecnología está redefiniendo las estrategias de investigación criminal.

Esta búsqueda de métodos útiles comenzó a fines de la década de 1980 (el primer perfil geográfico de delincuentes se creó en 1990), y hasta el día de hoy no hay consenso sobre cuál es la técnica más práctica de perfil geográfico de delincuentes (Bots, 2010). El debate actual sobre las estrategias de elaboración de perfiles se centra en gran medida en la complejidad del método a utilizar (Bennell et al., 2007).

Existe cierta controversia en el uso de medidas de tendencia central en el perfil geográfico (Levine y Associates, 2000; Paulsen, 2006; Snook et al., 2002), el empleo de múltiples medidas se justifica por su eficacia y por ser un enfoque intuitivo y ágil. Por otro lado, las distribuciones pueden ser limitadas y sensibles a los valores atípicos, no proporcionando una estrategia

sistemática para localizar la dirección de un delincuente en serie (Bennell et al., 2007; Levine, 2005; Rossmo, 2005). A pesar de sus limitaciones, estas técnicas son tomadas como referencia por los investigadores al compararlas con otras estrategias de perfilado geográfico (Levine, 2005; Paulsen, 2006). Este modelo se presenta como una herramienta valiosa tanto para descubrir nuevas estrategias como para fortalecer las ya existentes, con el objetivo de mitigar la delincuencia en serie (Kent, 2003).

La pregunta si es necesario utilizar técnicas complejas (estrategias de distancia de probabilidad) con herramientas como Rigel Criminal Geographic Targeting), CrimeStat IV Dagnet y Predator o, dicho de otro modo, ¿se pueden obtener resultados igualmente precisos con técnicas más simples? En este punto, no hay respuesta precisa, por lo que todavía hay mucho espacio para el desarrollo de perfiles geográficos de delincuentes, tanto para métodos clínicos como complejos.

El elemento esencial para la aplicación de estas herramientas digitales son los datos espaciales, que nos brindan un vistazo, aunque sea limitado, al mundo real. En esta línea, la técnica utilizada, ya se obtenga de métodos estadísticos avanzados o simples, no es tan crucial como la comprensión de la realidad que se obtiene de ella. Existe una tendencia creciente en diversas disciplinas, incluida la Geografía, hacia la interpretación y comprensión del comportamiento de la información, más que en centrarse únicamente en las técnicas analíticas. En consecuencia, nos encontramos con una renovada perspectiva en la que el principal propósito del análisis de datos no es meramente obtener salidas computacionales, sino interpretarlas de manera que faciliten una mejor comprensión del entorno real (Estebanez, 1987).

Aunque hay muchas estrategias diferentes disponibles para realizar perfiles geográficos, la mayoría de ellas se basan en los mismos dos supuestos teóricos:

1. la mayoría de los delincuentes en serie viven dentro del área cubierta por su actividad delictiva (domocentricidad),
2. la mayoría de los delincuentes en serie no viajan lejos de su ubicación de origen para cometer sus delitos (disminución de la distancia).

Las diversas estrategias de perfiles geográficos existentes pueden clasificarse ampliamente como estrategias de distribución espacial, estrategias de distancia de probabilidad y estrategias de distribución de dispersión (véase capítulo 4). Las estrategias de distribución espacial implican el uso de la distribución de las ubicaciones de los sitios del delito para calcular un punto central, que sirve como residencia prevista del delincuente. Ejemplos de estrategias comunes de distribución espacial incluyen el cálculo del centroide, el centro del círculo y el centro de distancia mínima (Snook et al., 2005). Las estrategias de dispersión espacial utilizan características geométricas de la distribución para hacer una predicción de un área determinada. Dentro de las estrategias de distribución de dispersión encontramos la geoforensis de Newton-Swoope, la elipse de desviación estándar, el diagrama de Venn, la priorización aritmética del centroide, el rectángulo límite mínimo y el método del gran círculo (Salafranca, 2020).

Estas estrategias varían en complejidad (algunas implican más cálculos para implementar que otras) y la suposición que a menudo se hace es que las estrategias más complejas superarán a las estrategias más simples.

Una estrategia sencilla para deducir el punto de anclaje de un delincuente en serie, basándose en las localizaciones de los crímenes, consiste en aplicar técnicas centrográficas, como el centro de distancia mínima o el centroide (Lebeau, 1987).

Las estadísticas centrográficas representan el tipo más elemental de descriptores para analizar la distribución espacial de los incidentes delictivos. Estos incluyen el centro de distancia mínima, el centro mediano, la desviación estándar de las coordenadas x e y , el centro medio, la desviación de distancia estándar; y la elipse estándar (Levine, 2002).

Cuando se aplican a la definición geográfica del delito, estas medidas resumen una distribución de escenas del crimen a un solo lugar donde la suma de las diferencias entre la media y todos los demás puntos dentro de la distribución es cero.

Para inferir el domicilio de un delincuente en serie, una práctica frecuente es considerar cada ubicación delictiva como si fuese una masa puntual y, a partir de ellas, determinar el centroide a través de una media espacial (Bun et al., 2010). No obstante, este tipo de análisis tiene sus restricciones. Cuando se analizan distribuciones usando dicha metodología, se enfrenta a la limitación de representar procesos multifacéticos con una única métrica descriptiva (Levine, 2006; Rossmo, 2000). De ahí que, a menudo, los análisis centrográficos se complementan con que reflejan la dispersión, como círculos, elipses, envolvente convexa mínima o modelos aritméticos que priorizan centroides. Esta amalgama de medidas de tendencia central con las de dispersión espacial ha probado ser una táctica de perfilado tanto simple como eficiente (Leitner et al., 2007; Levine, 2006; Paulsen, 2006; Snook y otros, 2002).

Resulta relevante destacar que, según investigaciones de Snook et al.(2002), la precisión obtenida mediante técnicas centrográficas ha sido comparable, y en ocasiones incluso superior, a la de métodos más elaborados.

Centrografia y geografía

El enfoque más habitual para analizar una secuencia delictiva consiste en predecir la localización del domicilio. La bibliografía sobre la investigación del itinerario delictivo de los delitos violentos en serie sugiere claramente que los delitos en serie siguen un patrón en torno al domicilio, el lugar de trabajo u otro lugar de actividad diaria del delincuente (Godwin, 1999; Holmes y De Burger, 1988; Kocsis y Irwin, 1997; Rossmo, 1999; Snook, Cullen, et al., 2005). Esto ha llevado a los investigadores a dedicar la mayor parte de sus recursos a desarrollar y evaluar métodos para encontrar este punto central del delito.

En este contexto se investiga las medidas centrográficas como puntos de referencia en la actividad diaria del delincuente. Para la mayoría de las investigaciones, este punto de referencia es el domicilio del delincuente en serie. Este método se ha probado con grandes conjuntos de datos y se ha comprobado que reduce diez veces el área de búsqueda necesaria.

Las medidas centrográficas se han utilizado hace casi un siglo, Hayford (1902) argumentó convincentemente que la medida más apropiada de ubicación de "centro de área" y "centro de población" es una estadística llamada promedio (media aritmética), así como para analizar la distribución de puntos en el espacio (Sviatlovsky y Eells, 1937; Yuill, 1971).

Los métodos centrográficos de la estadística espacial representan la forma más simple en el análisis de un patrón espacial de puntos y son extensiones bidimensionales de la estadística descriptiva unidimensional (no espacial).

El análisis de patrones de puntos se ocupa del tipo más simple de datos espaciales, un patrón de puntos o se utilizan para ilustrar la dispersión espacial de puntos alrededor del centro. Con esto nos referimos a un conjunto de datos que consiste en una serie de ubicaciones puntuales en una región de estudio en los que se han producido eventos de interés. Un patrón de puntos espaciales es simple porque los datos comprenden solo las coordenadas de los eventos al menos en el nivel más básico (Bailey y Gatrell, 1995). En general, las técnicas de análisis de patrones puntuales permiten comprender cuándo y dónde, los eventos de una distribución se organizan en el espacio ya sea aleatoria o regularmente o en grupos de diferente tamaño correspondientes a ciertas ubicaciones. Estos índices representan parámetros básicos de la distribución y, por lo tanto, sus propiedades de primer orden (Levine, 2002).

La centrografía se ha utilizado en una variedad de estudios criminológicos y contextos de investigación. La media espacial y los cambios en su ubicación a lo largo del tiempo se calcularon para los incidentes de violación en San Diego (LeBeau, 1987a). Un equipo de revisión de investigación ayudó a localizar la ciudad natal del destripador de Yorkshire desde el centro geográfico de los sitios de asesinato (Kind, 1987).

También utilizaron técnicas geoforenses en un análisis retrospectivo para centrarse en el área residencial de Angelo Buono, uno de los *Hillside Stranglers* (Rossmo, 2000). Se calcularon diferentes centros geográficos a partir de las coordenadas de las ubicaciones de los diferentes tipos de escenas del crimen (entre el punto de encuentro del ataque, el sitio donde se dejó el cuerpo y el

domicilio de la víctima). Además, se procedió a calcular un radio de búsqueda (circunscribiendo un área alrededor del centro geográfico donde se creía que era más probable encontrar a los asesinos), cuyo rango disminuyó a medida que se incorporaba la información espacial proporcionada por cada nuevo asesinato. Descubrieron que el centro geográfico donde se habían colocado los cuerpos predecía con mayor precisión la ubicación de residencia del asesino Angelo Buono (Rossmo, 1997).

Medidas de centralidad (centro medio)

El descriptor más simple de una distribución es el centro medio, es el promedio del centro de gravedad de la distribución espacial de un fenómeno.

El centro medio puede considerarse como un punto donde tanto la suma de todas las diferencias entre la coordenada X media y todas las demás coordenadas X es cero como la suma de todas las diferencias entre la coordenada media Y y todas las demás coordenadas Y es cero. El punto de la media aritmética suele ser bastante eficaz en la caracterización de un conjunto de puntos, especialmente si ese conjunto de puntos no contiene casos atípicos. Se podría esperar que el delincuente viva cerca del punto medio aritmético, al igual que algunas especies de arañas residen en el centro de su red (Chrysanthus, 1947).

Centro medio es la media de las coordenadas X e Y , siendo su representación matemática la siguiente:

$$\bar{X} = \frac{\sum_{k=1}^n X_i}{N} \quad \bar{Y} = \frac{\sum_{k=1}^n Y_i}{N} \quad (11.1)$$

donde X_i y Y_i son las coordenadas de ubicaciones individuales y N es el número total de puntos.

Cuando una serie de escenas del delito contiene uno o más de estos puntos distantes desviados, la media aritmética será un resumen bastante pobre del patrón de ubicaciones y puede no estar cerca de la residencia del delincuente. En la práctica, estos lugares se encuentran a menudo entre los delincuentes que cometen una gran proporción de sus delitos cerca de su lugar de residencia, pero otra proporción cerca de otro lugar relevante (lugar de trabajo, residencia familiar, etc.) (Brantingham y Brantingham, 1993; Polišenská, 2008). Una forma especial de este problema surge cuando la serie incluye dos grupos de delitos que forman grupos separados, como una serie de delitos cometidos alrededor del lugar de trabajo del delincuente y otra serie que comienza en su lugar de residencia. En estos casos, la media aritmética es una caracterización engañosa de la serie. El cálculo de la media tiene en cuenta todas las coordenadas, sin poder distinguir entre los diferentes grupos (van Der Kemp, 2014).




Figura 11-1. Efecto de los valores atípicos en la centrografía. (Caso Peter Sutcliffe. Tomado de *Why Crime Doesn't Pay : Locating Criminals Through Geographic Profiling* (p.6) por Morrow (2010).

El centro medio se encuentra en el rombo rojo (figura 11-1). Si se eliminaran los dos valores atípicos de la esquina inferior izquierda, el centro de masa se situaría en el triángulo amarillo.

Aunque varias de las escenas del crimen (puntos azules) de este ejemplo están situadas en un par de conglomerados superiores, el centro medio (punto rojo) está razonablemente alejada de los conglomerados. Si se eliminan los dos valores atípicos, el centro medio (punto amarillo) se sitúa más cerca de los dos conglomerados.

Alternativamente, podemos eludir el problema de la estabilidad incorporando el centro de mínima distancia.

Medidas de centralidad (centro de mínima distancia)

El centro de mínima distancia puede considerarse como una cantidad que ya se vincula de alguna manera a un principio teórico, el de la eficiencia de la elección de la ubicación. Se puede deducir de la teoría de Brantingham y Brantingham (1984), de que los delincuentes eligen los lugares a los que pueden llegar con el menor esfuerzo.

Al mismo tiempo, Neldner (2015), recoge la opinión de otros autores sobre el centro de mínima distancia, destacando que uno de los que consideran este centro también tiene una alta precisión en revelar la ubicación de la base de operaciones del delincuente merodeador.

El centro de distancia mínima de un conjunto dado de puntos en espacios euclidianos bidimensionales es la ubicación en la que la suma de las distancias a todos los demás puntos es la más pequeña, siendo tal centro el mejor predictor de dónde vive el delincuente (Levine, 2002) se define como:

$$W(\bar{x}, \bar{y}) = \sum_{i=1}^n \text{dist}\left((x_i, y_i), (\bar{x}, \bar{y})\right) \quad (11.2)$$

donde $\text{dist}()$ es la distancia euclidiana entre el punto (x_i, y_i) y el punto elegido (\bar{x}, \bar{y}) .

Obtener un valor preciso para esta compleja estrategia es más difícil que para otras estrategias de distribución espacial. El problema de minimizar W no es una tarea trivial, que se viene estudiando desde hace mucho tiempo. La función W es convexa, por lo que tiene un mínimo único en el casco convexo del conjunto de puntos dados.

En 1936, el matemático húngaro Endre Vaszonyi Weiszfeld (ahora conocido como Andrew Vaszonyi) propuso en Weiszfeld (1936), un algoritmo para encontrar la mediana espacial o el punto “*minisum*” en el plano euclídeo para valores grandes de m y pesos distintos.

Weiszfeld desarrolló un algoritmo, que puede aproximar la ubicación estimada de la casa a través del método iterativo de la siguiente manera:

$$(x^{(k+1)}, y^{(k+1)}) = \left(\frac{\sum_{i=1}^n \frac{x_i}{\text{dist}((x_i, y_i), (x^{(k)}, y^{(k)}))}}{\sum_{i=1}^n \frac{1}{\text{dist}((x_i, y_i), (x^{(k)}, y^{(k)}))}}, \frac{\sum_{i=1}^n \frac{y_i}{\text{dist}((x_i, y_i), (x^{(k)}, y^{(k)}))}}{\sum_{i=1}^n \frac{1}{\text{dist}((x_i, y_i), (x^{(k)}, y^{(k)}))}} \right) \quad (11.3)$$

donde el valor inicial puede tomarse como el centroide del conjunto dado (x^0, y^0) de puntos. Kuhn (1973), demostró que el método realmente converge al centro de distancia mínima, pero no se conoce una estimación precisa sobre cuánto tiempo tarda este método en converger, en función del número de puntos de entrada. Dado $(x^{(k)}, y^{(k)})$, el algoritmo de cálculo de $(x^{(k+1)}, y^{(k+1)})$ implica el inverso de las distancias entre $(x^{(k)}, y^{(k)})$ y los n puntos dados. Luego, se calcula la suma de los n números calculados en el paso anterior, que es seguido por el cálculo de $x^{(k+1)}$ e $y^{(k+1)}$ (Wang et al., 2018).

El algoritmo es robusto ya que los pesos son inversamente proporcionales a la distancia, y como resultado se descuentan los valores atípicos, teniendo poca influencia en los centros (Iyigun y Ben-Israel, 2010).

No existe una fórmula o ecuación única para calcular un centro de mínima de distancia exacto, según Mitchell (2005), es un proceso iterativo que implica calcular el centro medio, sumar

las distancias desde él a cada característica, compensar ligeramente el centro y sumar las distancias nuevamente hasta que finalmente se concentre en la ubicación óptima que tiene la suma más baja.

Para lograr el método de análisis, se ha implementado el modelo matemático (ecuaciones 11.1 y 11.3) con el algoritmo de Weiszfeld.

El código programado ha sido desarrollado por (Vardi y Zhang, 2000) utilizando el lenguaje de scripting Python para integrarlo en QGIS Development Team (2022).

Hay muchas técnicas disponibles que pueden generar perfiles geográficos, pero las herramientas comerciales que modelan un análisis Newton-Swoope o utilizan el centro de distancia mínima son escasas, a excepción de un programa llamado ATAC V.2014 9.1 (BAIR Analytics Inc., 2014) sin Acceso 2023. Otros métodos de perfilado geográfico que utilizan medidas de centralidad, es el llamado *Arithmetic Centroid Prioritization* (método de área de búsqueda que se basa en la distancia promedio de las escenas del crimen y el centro de distancia mínima), el programa llamado SPIDER (Paulsen, 2011) y el programa CrimeStat IV, (Levine, 2015).

Metodología

La modificación del método geoforenses de Newton-Swoope se basa en un algoritmo de cinco pasos:

1. Define un área de estudio utilizando el rectángulo delimitador mínimo de todos los delitos. Prácticamente, el área representa cientos de kilómetros cuadrados de los cuales cualquier ubicación dentro del área podría ser el refugio del delincuente.

2. Identifica las coordenadas medias aritméticas para cada desfase de los casos secuenciales de la serie para representar la aproximación del punto de anclaje. Se define en la ecuación (11.1). Donde \bar{x} representa la media de todas las x coordenadas de los incidentes, \bar{y} representa la media de todas las y coordenadas de incidentes para cada escena del delito de acuerdo con su secuencia (orden cronológico de todos los eventos delictivos), y kN es la población total de lugares de los delitos.
3. En el siguiente paso, la media central se modificará por el centro de distancia mínima para cada ubicación que se traza en un mapa en orden sucesivo para representar la aproximación del punto de anclaje (algoritmo de Weiszfeld). Se define en la ecuación (11.3) (véase capítulo 7, figura 7-3) “Diagrama de flujos de la implementación en QGIS del algoritmo de Yehuda Vardi y Cuin-Hui Zhang para el centro de distancia mínima”.
4. Se busca un radio decreciente que va amortiguándose alrededor de cada centroide, definiéndose el radio mediante la siguiente ecuación (11.4), donde R es el radio, A_{xy} es la distancia entre los puntos más lejanos y N es el número total de casos;

$$R = \frac{\sqrt{A_{xy}/\pi}}{N-1} \quad (11.4)$$

5. El proceso comienza con los primeros tres incidentes, dando como resultado el primer círculo (véase figura 11-2 y 11-3). Posteriormente, serán los primeros cuatro incidentes y así sucesivamente. Newton (1988) argumenta que, con cada delito

sucesivo, se obtiene una aproximación cada vez más precisa de la ubicación del "refugio". Asume que la ubicación prevista del "refugio" sigue un "patrón de búsqueda" que, después del cuarto o quinto caso, se acerca cada vez más al "refugio" real (Leitner et al., 2007).

Finalmente, estos círculos se superponen entre sí para producir un diagrama de Venn. El resultado es una serie de zonas de amortiguamiento en las que hay poca probabilidad de que se comente un delito porque está muy cerca de su punto de anclaje. El área de búsqueda final es conocida como el perfil superior (figura 11-2 y 11-3).

Las diferencias en la exactitud se evaluaron mediante diferentes métodos; Precisión dicotómica del perfil (es una prueba binaria de si la ubicación real del hogar cae dentro de la región del perfil superior, informando "sí" o "no"), distancia de error del perfil (es la distancia en línea recta entre la ubicación del punto de anclaje prevista y real) y el área del perfil superior (véase capítulo 3.2).

Datos

Como señala Rossmo (2000), el supuesto principal de un perfil geográfico es que el punto de anclaje seguro del delincuente se encuentra dentro de la distribución de los lugares del delito. En consecuencia, las características de movilidad representan un elemento crítico para proporcionar perfiles geográficos efectivos. Por cada ubicación del delito que se puede atribuir a un delincuente en serie, aumenta la precisión del perfil geográfico. En consecuencia, tanto Rossmo (2000) y Newton y Swoope (1987) proponen que se identifique un mínimo de cinco ubicaciones

distintas para el análisis (Kent, 2009). Para tener en cuenta este punto de vista, incluimos en nuestra muestra, la condición que un SHO debe haber cometido cinco o más incidentes.

Los casos de SHOs seleccionados para ser analizados son: Richard Ramírez; David Berkowitz; Peter Sutcliffe, Jeffrey Dahmer, Jhon Williams Jr.; William McDonald; Steve Wright; Lonnie Franklin; Chester Turner; Derrick Tood Lee (véase anexo A).

Para una comprensión profunda del modelo de Newton-Swoope, el caso de Peter Suttcliffe fue seleccionado del conjunto de datos utilizado en este estudio como una estrategia de diseño de investigación.

Entre los años 1975 y 1980 Peter Sutcliffe que llegó a ser conocido como el Destripador de Yorkshire, dejó un rastro de terror sobre el norte de Inglaterra. La mayoría de los ataques de Sutcliffe tuvieron lugar en las zonas rojas de las ciudades de Leeds y Bradford en el norte de Inglaterra, pero también en Manchester y varias ciudades más pequeñas en el condado de West Yorkshire. Después, se mudó de ciudad en ciudad sin cometer un crimen dos veces seguidas en el mismo lugar. Parece que cambió a diferentes áreas y direcciones para cometer los asesinatos, entre 1975 y 1977, con una serie de 8 crímenes, la dirección (punto de anclaje) estaba ubicada en 44 Tanton Crescent, Clayton Bradford; y, entre 1977 y 1980, con una serie de 12 crímenes, la dirección (punto de anclaje) estaba situada en 6 Garden Lane, Heaton y Bradford.

La serie total de crímenes de Peter Sutcliffe se ha dividido en dos series relacionadas con su domicilio, Peter Sutcliffe (Caso 1) y (Caso 2) respectivamente (figuras 11-2, 11-3).

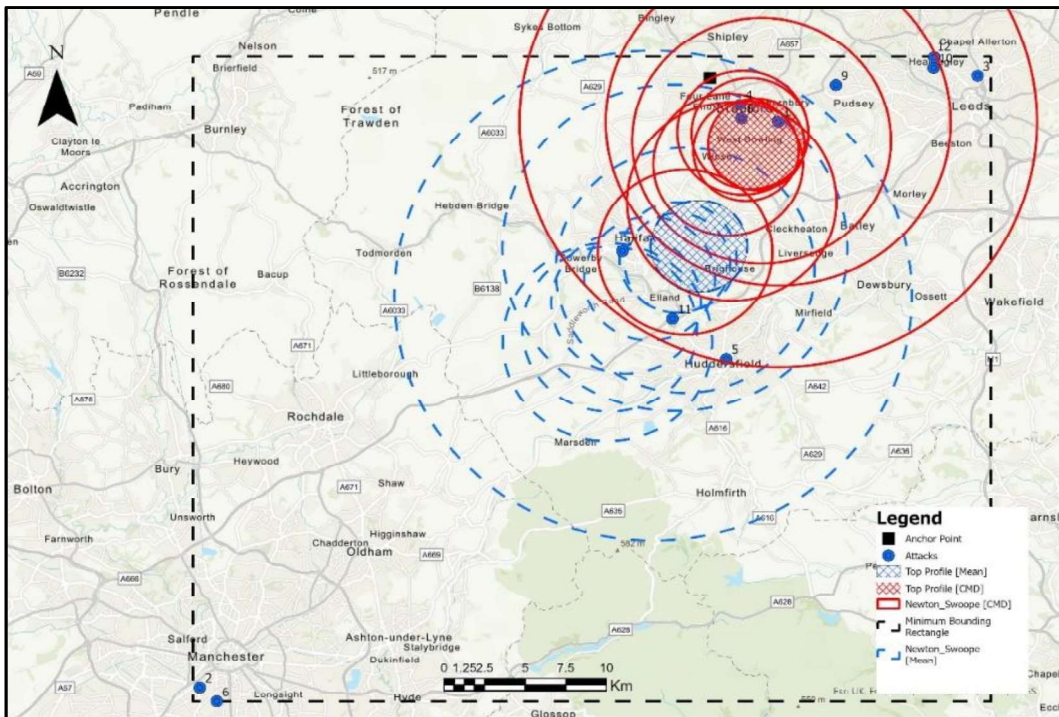


Figura 11-2. Peter Sutcliffe (Caso 1 Punto de anclaje)

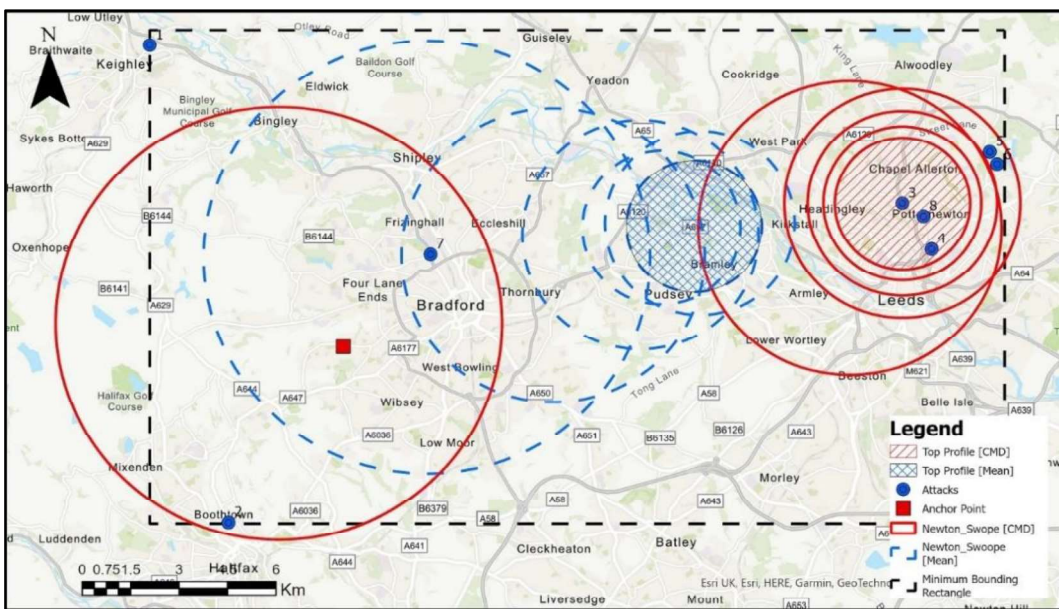


Figura 11-3. Peter Sutcliffe (Caso 2 Punto de anclaje)

Resultados

En la primera suposición, Newton y Swoope propusieron que después del quinto incidente, el "punto de anclaje" estimado se aproximaría al punto de anclaje real. Para probar esta suposición, se calcularon las distancias de error entre los puntos calculados por la media espacial y el centro de distancia mínima de la última serie y el punto de anclaje. La tabla 11-1 contiene las mediciones de distancia de error para las 11 series de delitos analizadas.

Conforme a lo indicado en la tabla 11-1, existió una diferencia significativa en la precisión de los perfiles elaborados utilizando el centro de distancia mínima. Más específicamente, en 8 de los 11 casos analizados, la distancia entre el centro de distancia mínima y el refugio es menor que utilizando el modelo de Newton-Swoope (centro medio).

Tabla 11-1

Distancia entre el punto de anclaje previsto y el real

SHOs	Número SHOs series	DEPA (Km) [CM]	DEPA (Km) [CMD]	del área área (Km ²) Perfil superior	Precisión perfil [CM]	Precisión perfil [CMD]
Richard Ramírez	16	28.71	12.31	1099.6	NO	YES
David Berkowitz	8	21.88	24.47	18.37	NO	NO
Peter Sutcliffe (caso1)	8	11.53	17.91	13.81	NO	NO
Peter Sutcliffe (caso2)	12	10.96	5.17	27.85	NO	NO
Jeffrey Dahmer	5	3.31	3.51	2.57	NO	NO
J. Williams Jr.	6	1.73	1.65	0.46	NO	NO
W.McDonald	5	145.69	0.111	9034.2	NO	YES
Steve Wright	5	0.388	0.300	0.08	NO	NO
Lonnie Franklin	12	0.622	0.168	0.47	NO	YES
Chester Turner	13	11.74	11.22	0.41	NO	NO
Derrick Tood Lee	6	4.22	0.861	7.00	NO	YES

Nota. (CM) Centro medio.; (CMD) Centro de mínima distancia; (DEPA) Distancia entre el punto estimado y el actual punto de anclaje.

El segundo supuesto estableció que el punto de anclaje real se encuentra dentro de las áreas de búsqueda después del cuarto delito. En este caso, se ha utilizado la precisión del perfil para dar respuesta al enfoque de Newton. Los cálculos se pueden observar en la tabla 11-1 y muestran un 63,6% (7 de 11) de todas las series, en el modelo del centro de distancia mínima y un 100% para el modelo Newton-Swoope (centro medio). Sin embargo, el "punto de anclaje" real cae fuera de cualquiera de las áreas de búsqueda previstas con cinco o más casos.

La tercera suposición establece que el área de búsqueda se hace más pequeña con cada delito sucesivo después de la quinta serie.

Para analizar el segundo supuesto, se calcularon áreas de búsqueda para cada serie de cinco o más delitos, comenzando con la última serie.

Los resultados en la tabla 11-2 muestran una tendencia de disminución de las áreas de búsqueda de 78,75 para la serie 6 a 52,1% para la serie 9, produciendo una tendencia de subida a partir de la serie 9 hasta la serie 11 con un aumento del 69%. Sin embargo, estos resultados no confirman, en principio, el supuesto de que el área de búsqueda se vuelve más pequeña con cada robo sucesivo después del quinto caso.

Tabla 11-2*Perfil superior del área de búsqueda de los últimos lugares de ataque*

SHOs	AFS (Km ²)	AFS (Km ²)	AFS (Km ²)	AFS (Km ²)	AFS (Km ²)	AFS (Km ²)
Richard Ramirez	9.4	7.8	6.5	6.5	1118	1099
D. Berkowitz	55.9	26.7	37.6	4.8	17.2	18.3
P.Sutcliffe (caso1)	150.1	69.2	41.9	7.0	18.8	13.8
P.Sutcliffe (caso2)	90.8	66.7	51.0	0.9	33.1	27.5
Jeffrey Dahmer	-----	-----	-----	0.3	4.2	2.57
J. Williams Jr.	-----	-----	2.14	0.28	0.72	0.46
W. McDonald	-----	-----	-----	5943	15974	9036
Steve Wright	-----	-----	-----	0.35	0.15	0.08
Lonnie Franklin	1.14	0.93	0.71	0.56	0.52	0.47
Chester Turner	0.015	0.031	0.025	0.030	0.32	0.41
D. Tood Lee	-----	-----	15.5	6.2	10.9	7.0

Nota: (AFS) Área Final Serie.**Discusión**

En el análisis de datos criminológicos, es frecuente encontrar variables espaciales con valores atípicos (outliers), los cuales se desvían mucho del resto de los valores y caen fuera del patrón general de distribución de la variable. Varios autores han propuesto diferentes definiciones para estos valores y han desarrollado métodos muy variados para identificarlos y manejarlos. Existe una gran controversia en la literatura en relación con la eliminación de los valores atípicos. Se ha planteado que se debe conocer su causa y la influencia que pueden tener en los resultados de los experimentos, antes de tomar la decisión de eliminarlos o incluirlos en el análisis, porque cambian las inferencias que se obtienen y, en ocasiones, su eliminación puede conducir a la pérdida de una información importante.

Según Rossmo et al. (2005), los valores atípicos anómalos complican la creación de perfiles geográficos, dado que pueden influir desmesuradamente en el perfil final. Aunque se pueden tolerar en pequeñas cantidades, es recomendable identificar y descartar estos valores. La experiencia en múltiples casos ha evidenciado que, en su mayoría, estos datos atípicos resultan ser errores o reflejantes comportamientos verdaderamente inusuales, como un desplazamiento excepcional del sospechoso fuera de su espacio de actividad habitual. En este caso propone seleccionar escenarios para un análisis detallado.

Este capítulo describe cómo el algoritmo de Weiszfeld aplicado a un perfil geográfico ha introducido medidas sólidas para centrar los datos en presencia de valores atípicos. La facilidad de implementación hace que el algoritmo propuesto sea atractivo en estrategias de perfiles geográficos de bajo costo. Este algoritmo puede ser una solución, especialmente si la evidencia empírica sugiere que la estrategia más simple puede dar resultados comparables con otras estrategias de perfilado.

Como Rossmo (1999) tuvo cuidado de señalar, el perfilado geográfico no busca ofrecer una estimación puntual para el punto de anclaje, como intenta hacer métodos como la media espacial, la mediana espacial y el centro de distancia mínima. En cambio, describe una estrategia de búsqueda óptima. Debido a la complejidad de las superficies de probabilidad, la distancia desde el punto con más probabilidad del geoperfil hasta el punto de anclaje es irrelevante. Lo esencial es determinar qué porcentaje de puntos dentro del área de estudio posee valores Z superiores al punto de referencia (véase capítulo 3).

Podemos encontrar una cierta similitud con el área del perfil superior de Newton para encontrar la estimación propuesta por Rossmo, desde el punto de vista que el modelo *Criminal*

Geographic Targeting se clasifica desde una estrategia de distancia de probabilidad y el modelo de Newton-Swoope desde una estrategia de dispersión.

La principal limitación del modelo Newton-Swoope es el radio de búsqueda, porque el comportamiento de viaje del perpetrador hacia y desde la escena del crimen se calcula sobre una superficie de propagación geoespacial isotrópica, en la que las posibles resistencias del territorio se calculan y valoran uniformemente en todas las direcciones de movimiento, de modo que cualquier lugar dentro del radio tiene la misma probabilidad de ser el punto de anclaje del delincuente. Aunque Newton reconoce el importante impacto que el paisaje tiene en la comisión de un acto delictivo, no se intenta encajar en el modelo una superficie anisotrópica al estimar el domicilio.

En conjunto, las medidas de distancia de error del perfil y el área del perfil superior proporcionan una indicación de la precisión (área del perfil superior) y la exactitud (distancia de error del perfil) de un perfil. Esto es importante porque en el perfil geográfico, tanto la precisión como la exactitud son necesarias para enfocar eficazmente los esfuerzos de investigación. Específicamente, un perfil puede ser preciso (la ubicación real del hogar está dentro o cerca de la región del perfil superior) pero no preciso (la región del perfil superior es muy grande), lo que no proporcionaría mucho beneficio práctico a una investigación (Paulsen, 2006).

Esta distancia de error es un estimador bruto que nos dice cómo priorizar las ubicaciones junto con la segunda parte de la ecuación (11.4), el perfil superior. Los críticos de la investigación centrada en los jueces humanos han argumentado que la distancia de error no es una medida estadísticamente sólida de la precisión del perfil geográfico y que el uso del porcentaje de puntuación de éxito refleja mejor cómo se utilizan los perfiles geográficos en las investigaciones

policiales (Rossmo, 2011). Por el contrario, los usuarios de la distancia de error han señalado que puede calcularse fácilmente y aplicarse sin problemas a todos los métodos de perfilado geográfico, incluidos los que no producen áreas de búsqueda (es decir, estrategias que resultan en un único punto de predicción) (Snook et al., 2005).

Si bien los perfiles geográficos han capturado la imaginación tanto del público como de la comunidad policial, hasta ahora ha habido poca investigación sobre la precisión del modelo Newton-Swoope. Al observar los resultados de este análisis, se pueden extraer una serie de conclusiones importantes con respecto a la precisión de los modelos discutidos (centro medio y centro de distancia mínima).

En cuanto a la evaluación del perfil geográfico, esta prueba ha demostrado que el mejor comportamiento del centro de distancia mínima se ha obtenido en la proximidad sucesiva del punto estimado con el domicilio en cada serie, a partir del quinto incidente. En la figura 11-2 y 11-3 se puede observar el desplazamiento del perfil superior (zona circular azul) a los valores de los incidentes más alejados. En el caso del perfil superior (zona circular roja) que equivale al modelo del centro de mínima distancia, el desplazamiento es menor. El resultado esperado puede ser de gran utilidad para analizar modelos de perfiles geográficos en organizaciones policiales.

El estudio confirma investigaciones anteriores de Levine, 2005; Paulsen, 2006; Snook, 2005, muestran que el centro de distancia mínima es a menudo una mejor medida de la tendencia central de una distribución.

El segundo supuesto estudiado ha sido el menos acertado, sólo en el modelo del centro de distancia mínima, en 4 perfiles superiores de 11, el punto de anclaje real se sitúa dentro del área del perfil superior y, en todo caso, el modelo de centro medio no ha situado ningún punto de anclaje

en el área del perfil superior. No ha tenido la respuesta esperada y no podemos considerar una condición adecuada para determinar el perfil superior como parámetro de superficie de riesgo para localizar el punto de anclaje.

El tercer supuesto considerado, donde el área de búsqueda se hace más pequeña con cada delito sucesivo después del cuarto o quinto delito, no dio el rendimiento esperado en cuatro series criminales (36,3%) de los once delitos estudiados (63,7%).

En primer lugar, en términos de precisión general, podríamos considerar la estrategia del modelo del centro de distancia mínima como "buena", en comparación con el modelo tradicional de Newton-Swoope.

Además, una característica de los conjuntos de datos explica que al ajustar la muestra a los criterios de investigación (5 delitos), las muestras no fueron demasiado grandes (10 SHOs y 90 series), por lo que esto puede reducir la efectividad general y la confianza en la investigación del análisis, lo que sugiere cierta precaución sobre la generalización de estos resultados.

Sin embargo, cabe señalar que la base científica aún no es tan sólida como podría parecer a primera vista. Esto se debe en parte a que el perfil geográfico de los delincuentes es un método de detección bastante nuevo. Como resultado, todavía hay mucho debate entre los científicos sobre qué teorías usar. Esto explica en parte la diversidad de técnicas y opiniones existentes sobre cuán complejos deben ser los perfiles (Bots, 2010).

Por lo tanto, la investigación futura debe aplicar el método de análisis a otros delitos seriales no probados en este estudio, con el fin de compararlo con otros métodos de distribución de probabilidad de perfil geográfico.

Capítulo 12

MERODEADORES Y VIAJEROS

Resumen

Canter y Larkin (1993), han establecido una distinción fundamental entre dos tipos de delincuentes en serie en términos del comportamiento espacial del delincuente durante la ejecución de su serie de delitos, categorizándolos en estilos de viajeros “*commuters*” y merodeadores “*marauders*”. Estos dos enfoques representan paradigmas en contraposición respecto al comportamiento espacial del delincuente, donde el lugar del domicilio del delincuente influye en la elección del lugar donde comete el delito. La investigación para determinar el tipo de delincuente merodeador antes de realizar un perfil geográfico es esencial dada la incapacidad del software actual de elaboración de perfiles geográficos para perfilar con precisión las series de los viajeros. Este esquema de clasificación coloca a todos los infractores en una de dos categorías según la relación espacial entre sus sitios de delincuencia y los puntos de anclaje. Por lo tanto, estos modelos son inadecuados para los delincuentes que viajan a objetivos alejados de sus puntos de anclaje para cometer sus crímenes, pero son aplicables a delincuentes merodeadores que se abren en abanico desde un punto de anclaje central en busca de oportunidades criminales. Estas limitaciones han llevado a una comprensión incompleta de las distinciones entre los delincuentes viajeros y merodeadores y un obstáculo general en el perfil geográfico. Este estudio tiene como objetivo superar esta limitación aprovechando la interpretabilidad de los modelos avanzados de aprendizaje automático. Los resultados indican de manera significativa que es posible validar la distinción conceptual entre los estilos de delito de viajeros y merodeadores.

Introducción

Canter y Larkin (1993) establecieron una distinción esencial entre dos categorías de delincuentes en serie, basándose en el comportamiento espacial del delincuente a lo largo de su serie de delitos.

Se considera que los merodeadores “*marauders*” actúan en una zona próxima a su lugar de residencia, mientras que los viajeros “*commuters*” cometen delitos en lugares percibidos como distantes del lugar del domicilio del delincuente.

Este esquema de clasificación de delincuentes sitúa a todos los delincuentes en una de las dos categorías basadas en la relación espacial entre sus lugares de comisión de delitos y su punto de anclaje. Específicamente, el delincuente se desplaza fuera de su domicilio para cometer los delitos (véase figura 12-1). Esto puede deberse a que el delincuente tenga que desplazarse debido a la escasez de objetivos cerca de su domicilio o a que descubra un grupo de objetivos adecuados durante un comportamiento espacial no relacionado con el delito (Canter y Larkin, 1993).

Además, esta lejanía de la base de operaciones permite al delincuente distinguir un área para las actividades no delictivas y otra para la comisión delictiva (Brantingham y Brantingham, 1981). En resumen, Canter y Larkin (1993) afirman que el lugar de origen y el de la ejecución del delito apenas coinciden físicamente en el modelo del viajero, pero sí en el modelo de merodeador.




Figura 12-1. Viajero y Merodeador modelo basado en Canter & Larkin “Circle Hypothesis” adapted from Petherick, W. (2009). *Serial Crime: Theoretical and Practical Issues in Behavioral Profiling* (2nd ed.). Burlington, MA: Elsevier Academic Press.

La distinción propuesta entre merodeadores y viajeros surge originalmente del modelo de Canter y Larkin (1993) sobre el comportamiento espacial de los delincuentes durante la ejecución de delitos en serie. Este modelo se conoce como la “*Circle Theory of Environmental Range*” y describe el comportamiento espacial delictivo como un comportamiento que guarda una relación significativa con la base o lugar de residencia del delincuente. Durante los desplazamientos, tanto

delictivos como no delictivos, desde su lugar de origen, los delincuentes toman conciencia de su entorno y, posteriormente, utilizan esta información para identificar objetivos potenciales.

En consecuencia, el epicentro de la serie de crímenes difiere de la base de operaciones, evitando así que los ámbitos del hogar y del delincuente se encuentren (véase figura 12-1).

Rossmo (2000) presenta un problema esencial: ¿cómo determinar a cuál de las dos categorías pertenece un delincuente serial?

Rossmo categoriza a estos delincuentes como "cazador local" (*local hunters*) para referirse a la tipología de merodeador y "cazadores furtivos" (*poachers*), que se asemeja a la de viajero.

Ante una serie de delitos sin detención del delincuente de homicidio en serie (en adelante SHO), ¿cómo se hace esta distinción? Rossmo sugiere que, antes de iniciar la perfilación geográfica, se debe determinar si el delincuente es un "cazador local". Sin embargo, no especifica cómo hacer esta distinción. Aunque existe un documento de Rossmo que señala los factores de los "cazadores " o "viajeros", este no ha sido publicado ni validado empíricamente (van Der Kemp y van Koppen, 2007).

Otra de las cuestiones de sustancial importancia respecto al perfil geográfico viene expresada por los requisitos teóricos y metodológicos más importantes y que se requieren para poder realizar el perfil. Rossmo (2000), identifica al menos cuatro supuestos que se requieren a la aplicación de la elaboración de perfiles geográficos;

- El caso involucra una serie de al menos cinco delitos, cometidos por el mismo delincuente. La serie debería estar relativamente completa, y cualquier delito faltante no debería tener un sesgo espacial (Puede tratarse de lugares de diferentes delitos o de varios lugares asociados al mismo delito).

- El delincuente tiene un único punto de anclaje estable durante el período de tiempo de los delitos.
- El delincuente está utilizando un método de caza apropiado.
- El telón de fondo es razonablemente uniforme.

La clasificación del comportamiento de desplazamiento de un delincuente tiene una relevancia significativa en el perfilado geográfico. Diversos investigadores, como (Canter y Larkin, 1993; Kocsis y Irwin, 1997; Meaney, 2004), han subrayado las implicaciones que surgen de las diferencias entre merodeadores y viajeros y cómo estas pueden afectar la elaboración del perfil geográfico de los delincuentes. A pesar del debate actual sobre las precisas limitaciones de la perfilación geográfica, existe un consenso amplio en que dichos perfiles deberían centrarse primordialmente en series delictivas donde el delincuente actúa como merodeador o como delincuente local (Laukkanen y Santtila, 2006; Rossmo, 2000; Rossmo, 2005b; Snook, Taylor, et al., 2005).

Sin embargo, se ha observado que determinadas herramientas de software, han pasado por alto cuestiones cruciales vinculadas a las limitaciones inherentes al perfilado geográfico (Canter, 2005; Gregory, 2005; Rossmo, 2005b; Snook, Zito, et al., 2005). Una de estas omisiones destacadas es la identificación precisa del tipo de delincuente, ya sea merodeador o viajero. En la actualidad, el software informático de elaboración de perfiles geográficos más conocidos Dragnet (Canter, 1995), Rigel (Rossmo, 1997c), Predator (Godwin, 2001b) y CrimeStat IV (Levine, 2015) asume un modelo de comportamiento de merodeador en su predicción del área de residencia más probable de un delincuente en serie.

Con la única excepción del software SPIDER⁶ (*Spatial Pattern analysis for Investigative Decision making Exploration and Response*) (Paulsen, 2011), esta herramienta incluye un módulo diseñado para determinar si los datos de una serie corresponden a un patrón de comportamiento de un merodeador o de un viajero. Este análisis se basa en un estudio realizado sobre 106 delincuentes seriales (Paulsen, 2007). La figura 12-2 y 12-3 ofrece una muestra de los diagnósticos del caso I (véase capítulo 6.9.1) utilizando un proceso de estandarización.




Figura 12-2. Diagnostico SPIDER (Merodeador o Viajero)

Esta tabla permite al usuario analizar visualmente el caso actual en comparación con la base de datos de investigación utilizando valores estandarizados.

⁶ SPIDER utiliza el visualizador MapPoint América 2009 [descatalogado por Microsoft].

Commuter/Marauder Analysis				
Label	Commuter	Series	Marauder	NormalizedValue
Total number of crimes	5	20	8	-9
Normalized Weighted Average				16.42998869057...
Nearest neighbor index	1.61425	0.402523265329...	1.1452	-4.16672736241...
Intensity	0.1739	20	0.1096	617.6749611197...
Dispersion (miles)	4.975	40.86882781982...	10.57	-11.8306801858...
Average Travel Distance from CMD (miles)	1.318	8.9061134070158	3.211	-7.01702420181...
Average days between crimes	6.783	0	9.6666	5.704535996670...
Area of offense domain (sq. miles)	15.113	1106.277541266...	58.794	-48.9606026083...
Area of convex hull	2.61	317.8704206447...	21.76	-31.9253703023...
Area of circle between 2 most distant crim...	19.47	1311.818882364...	80.71	-41.2060379609...
Area of a Standard Deviation Ellipse	5.688	0.090142707124...	20.433	1.759288883401...

Figura 12-3. Interpretación SPIDER Variables (Merodeador o Viajero)

Cada prueba diagnóstica es una columna separada (etiquetada a la derecha), con valores que se acercan a (+1) siendo similares a los viajeros “*commuters*” y (-1) siendo similares a los merodeadores “*marauders*”. El propósito del gráfico es proporcionar al usuario un indicador de la validez del perfil geográfico.

Clasificación

La clasificación dicotómica de los asesinos en serie en merodeador o viajero es ampliamente citada y utilizada, es una clasificación que depende de la demarcación geográfica de su área de distribución. En este marco, podemos señalar:

Modelo Canter y Larkin (Circle Theory of Environmental Range)

La distinción propuesta entre merodeadores y viajeros surge originalmente del modelo de Canter y Larkin (1993) sobre el comportamiento espacial de los delincuentes durante la ejecución de delitos en serie. Este modelo es conocido como “*The Circle Theory of Environmental Range*” y representa el comportamiento espacial delictivo como si tuviera una relación significativa con la base o lugar de residencia del delincuente.

Canter y Larkin (1993) examinaron el comportamiento espacial de 45 agresores sexuales en serie del Reino Unido y descubrieron que el 87% de la muestra mostraba un estilo delictivo merodeador, lo que sugiere que la ubicación de la base de operaciones desempeña un papel integral en la elección del lugar del delito por parte del agresor y, posteriormente, en la selección de la víctima (cometen sus delitos en su domicilio como nexo de la actividad delictiva, desde donde los delitos se extienden a los alrededores).

Sugirieron que esto puede atribuirse o bien a que el agresor sexual intenta economizar movimientos durante la actividad delictiva, o bien a la posibilidad de que el estilo delictivo merodeador sea simplemente una etapa evolutiva del comportamiento delictivo. El delito de agresión sexual es un acto altamente emocional, por lo que el delincuente con un estilo delictivo merodeador puede tener una necesidad psicológica de mantener la proximidad a la base del hogar, posiblemente para permitir una sensación de seguridad.

En su representación más simple, el patrón físico del movimiento del delincuente puede concebirse como un círculo que abarca la ubicación del domicilio en el centro. El radio del círculo es representativo de la distancia entre el domicilio del delincuente y el sitio del delito más alejado. La distancia entre el lugar de origen y el lugar del delito más lejano se denomina "*criminal range*"

y se define como la mayor distancia que un delincuente está dispuesto a recorrer para cometer un delito. Se sugiere que el comportamiento espacial del delincuente en una serie de delitos sea interpretable en relación con su base de operaciones, ya que todos los sitios de delitos serán relativos a esta ubicación (Canter y Gregory, 1994).




Figura 12-4. Modelo viajero. El círculo negro corresponde al domicilio.




Figura 12-5. Modelo merodeador. El círculo rojo corresponde al domicilio.

La clasificación entre merodeador y viajero a menudo se reduce a un solo criterio geométrico simple, utilizando la hipótesis del círculo. Si el círculo que une los dos delitos más lejanos contiene la residencia del delincuente, el delincuente se clasifica como viajero (véase figura 12-4) de lo contrario, se lo denomina merodeador (véase figura 12-5).

Este criterio es altamente dependiente de la distancia entre los dos delitos más lejanos. La caracterización no es tanto una característica estable del delincuente, sino un marcador de posición

de su comportamiento de viaje criminal. Una variación de la definición del rango criminal que es el círculo. Un problema adicional es el modelo mixto, donde en una serie delictiva un delincuente puede ser clasificado como un viajero, pero en el momento siguiente, después de otro crimen, como un merodeador (véase figura 12-6). El problema de este método, a pesar de sus consecuencias, es el que menos atención parece haber recibido por parte de la literatura o, al menos, el que menos soluciones convincentes presenta, como advierten (Zhu y Zhang, 2012).




Figura 12-6. Modelo Mixto

Modelo Warren (Convex Hull Polygon)

Warren et al. (1998), diseñaron dos modelos para examinar los patrones geográficos espaciales basados en dos parámetros dicotomizados:

El modelo “*Convex Hull Polygon* “(en adelante CHP) o envolvente convexa, se define como el polígono convexo de menor área dentro del cual contienen todos los puntos del conjunto,

para caracterizar y examinar los patrones espaciales de los delincuentes en serie. Warren et al. (1998) creó cuatro modelos geográficos basados en dos parámetros dicotomizados: residencia del delincuente (dentro o fuera del CHP) y distancia media a los sitios del crimen (cerca o lejos).

El modelo se basa la simetría en la elección de la ubicación de un delincuente; evidentemente, con el diseño del polígono se esperan efectos de restricción, los cuales limitan a los infractores al elegir un lugar para cometer su delito (van der Kemp y van Koppen, 2007).

El otro modelo diseñado es el de merodeador y viajero (Canter y Larkin, 1993) y ambos se utilizaron para explorar la relación entre los delitos y la ubicación del domicilio del delincuente (véase figura 12-10).

Kocsis (2007), en base a la teoría circular, busca posibles aplicaciones prácticas para la investigación al investigar cuántos incidentes delictivos (y múltiples ubicaciones) le dan al círculo una representación de la ubicación donde vive el delincuente. Su descubrimiento fue que el círculo basado en los primeros cuatro delitos generalmente contenía la ubicación de domicilio del delincuente (véase figura 12-7) y que este círculo era más pequeño, en el 69% de los casos, que el círculo que se basaba en todos los delitos en la serie. Señala, con razón, que esto solo es de utilidad en casos en los que el delincuente actúa como un merodeador. Kocsis (2007) en su estudio, amplía este modelo analizando la evolución de la distancia en las series criminales. Exploró cómo los delincuentes, a medida que avanzaban en su serie de delitos, tendían a cometer estos más cerca o más lejos de sus domicilios, llegando a la conclusión de que los delincuentes se acercaban a sus domicilios cuando cometían más incidentes delictivos.




Figura 12-7. Modelo Kocsis. Los círculos verdes representan los cuatro primeros delitos

Paulsen (2007), desarrolla una metodología (priorización del centroide aritmético), en la que utiliza el algoritmo del centro mínima distancia (en adelante CMD) de todos los incidentes delictivos, para calcular la distancia media entre los incidentes y el CMD, generando posteriormente un círculo de radio igual al resultado de la distancia media.

Los resultados se deben interpretar como indicadores de que la base del delincuente (merodeador) es más probable que se encuentre dentro del círculo (véase figura 12-8).




Figura 12-8. Modelo de Priorización del centroide aritmético

O'Leary (2011), crea otro enfoque para clasificar a los delincuentes viajeros o merodeadores. La definición clásica de merodeador y viajero (Canter y Larkin, 1993) es una caracterización binaria que trata a delincuentes similares bastante diferentemente. De hecho, si el punto de anclaje de un delincuente está bastante cerca del círculo límite, entonces se clasificaría únicamente sobre la base de qué lado de la línea límite se encuentra el punto de anclaje, incluso si esa distancia simplemente cruza una calle. O'Leary ha desarrollado un enfoque más matizado que asocia un número μ entre cero y uno a una serie, se considera que los infractores con valores cercanos a cero se comportan como viajeros mientras que los infractores con valores cercanos a uno se comportan como merodeadores. Para proporcionar un enfoque más matizado, se construyó

un modelo con una puntuación matemática para que un delincuente mida en qué medida el patrón observado se parece al de un merodeador y al de un viajero (véase figura 12-9).




Figura 12-9. Enfoque O'Leary (merodeador o viajero)

En este capítulo se analiza los modelos de demarcación descrito por Canter y Larkin (1993) y el modelo envolvente convexa (Warren et al., 1998), permitiendo así comparar los resultados obtenidos con estudios anteriores que utilizaron el método del círculo de Canter y Larkin (Górski, 2018; Kocsis et al., 2002; Kocsis y Irwin, 1997; Meaney, 2004; van Der Kemp, 2014).




Figura 12-10. Demarcación Circular y Envolverte convexa. Viajero y merodeador. (A) merodeador convexo y circular, (B) merodeador circular merodeador convexo, y (C) merodeador convexo y circular. Adaptado de *Journal of Investigative Psychology and Offender Profil*

Merodeador o Viajero

Determinar el tipo de delincuente merodeador previamente a la realización de un perfil geográfico es crucial, dada la limitación del software actual para perfilar adecuadamente las series de viajero, sumado a la elevada presencia de estos últimos entre los delincuentes.

Sorprendentemente, aunque la literatura ha debatido teóricamente sobre las características que podrían distinguir entre ambos patrones, ha existido una escasa exploración empírica real de sus diferencias. Además, rara vez se ha puesto a prueba la validez de esta metodología de clasificación. A esta situación se suma el hecho de que poco se ha considerado a aquellos

delincuentes que exhiben ambos patrones espaciales a lo largo de su trayectoria delictiva (Lundrigan y Czarnomski, 2006).

Pese a la relevancia que tiene distinguir entre viajero y merodeador para la elaboración de perfiles geográficos, son escasos los estudios publicados que buscan predecir la categorización de estos delincuentes basándose en variables de series delictivas (Beijsterveldt, 2006; Górski, 2018; Paulsen, 2007; Pulinckx, 2006). El primer problema con la investigación previa involucra las variables utilizadas para la predicción, en ocasiones se basan en información que probablemente no se conozca antes de la detención (raza, sexo, edad e intoxicación por alcohol) (Meaney, 2004).

Sin embargo, recientemente, la investigación ha comenzado a centrarse en tratar de determinar si existen factores medibles que diferencien estos dos tipos de delincuentes.

Algunos estudios infieren que el perfil de movilidad del delincuente con la información disponible al comienzo de una investigación, en la investigación realizada por Paulsen (2007), los tipos de delitos varían desde incendio, asesinato, robo (comercial y callejero), robo y asalto sexual y provienen de una combinación de jurisdicciones que pueden caracterizarse como rurales, urbanas o suburbanas. De las 106 series de delitos (64 eran merodeadores y 42 viajeros), las series varían desde 3 delitos a 42 delitos, con una media de 10 delitos por serie. Los datos para el análisis se dividieron en categorías de viajeros y merodeadores siguiendo una versión modificada del procedimiento descrito por Canter y Larkin (1993). Es importante destacar que, dado que esta investigación estuvo al tanto de todos los puntos de anclaje conocidos de los infractores, la clasificación de viajero y merodeador se modificó ligeramente para este análisis. Específicamente, en lugar de mirar simplemente el domicilio, la presencia de cualquier punto de anclaje dentro del círculo clasificó al agresor como un merodeador. Esta es una modificación importante de la

categorización de Canter y Larkin (1993), ya que analizar solo las ubicaciones residenciales puede clasificar incorrectamente a un infractor como un viajero a pesar de que tienen otros puntos de anclaje dentro de la zona de infracción.

La metodología utilizada en la investigación se basa en regresión logística sobre una serie de variables espaciales y temporales para un conjunto de series de delitos que serían conocidas o que un investigador podría calcular fácilmente (véase figura 12-3). Es importante destacar que la gran mayoría de las variables predictoras son variables geográficas o temporales que miden la distancia y el área de la ubicación del delito. Los resultados obtenidos mejoraron las predicciones de la clasificación de delincuentes de un 60% de la mejor estimación al 81%. El modelo fue estadísticamente significativo (chi-cuadrado 46.644, $p < 0.0001$) y explicó 0.489 de la variación (Nagelkerke R^2).

Dos variables espaciales contribuyeron significativamente al aumento de la previsibilidad: el área del polígono convexo, que delimita las ubicaciones de los delitos, y el valor del índice del vecino más cercano (NNI, por sus siglas en inglés). Se observó que las series de delitos de los merodeadores ocurren en áreas significativamente más grandes y presentan una dispersión de ubicaciones de delitos menos concentrada. En relación con estas variables, el intervalo de días entre los delitos también resultó significativo.

De estas tres variables, el NNI demostró tener el mayor impacto en las predicciones correctas. Dado que el índice del vecino más cercano es una medida del grado de agrupación de puntos en una distribución, esto sugiere que la agrupación de las ubicaciones del delito influye significativamente en la predicción del tipo de delinciente.

En el estudio de Haaglands (Beijsterveldt, 2006; Pulinckx, 2006; van Der Kemp et al., 2005), van Beijsterveldt, (2006) y Pulinckx (2006), bajo la dirección de van Der Kemp, llevaron a cabo una investigación sobre la distinción entre merodeadores y viajeros, en relación a los métodos de demarcación del círculo descrito por Canter y Larkin (1993) y la envolvente convexa mínima descrito por Warren et al. (1998). El estudio plantea la siguiente hipótesis;

¿Hasta qué punto es posible determinar el tipo de delincuente sobre la base de las características de los delitos en una serie antes de la detención?

La tipología delictiva utilizada en el estudio se basa en delitos contra la propiedad realizados en región policial de Haaglanden (Holanda). De los 1609 delincuentes analizados, cometieron en su conjunto 30.914 delitos (1062 eran merodeadores y 547 viajeros), en la clasificación de la hipótesis de círculo (708 eran merodeadores y 901 viajeros), en la clasificación de envolvente convexa (*convex hull*), las series varían desde 6 delitos a 56 delitos. Los datos para el análisis se dividieron en categorías de viajeros y merodeadores siguiendo una versión modificada del procedimiento descrito por Canter y Larkin (1993).

La metodología utilizada en el estudio, también se basa en una regresión logística en una serie de variables para un conjunto de series de delitos que serían conocidas o que un investigador podría calcular fácilmente.

Cinco variables contribuyen significativamente a la predicción de si un delincuente es un merodeador o un viajero en el modelo del rango del círculo. La probabilidad de que un delincuente sea clasificado como merodeador se incrementa en relación con la frecuencia y la intensidad de sus delitos, especialmente si ha empleado violencia en al menos uno de ellos, y si existe un aumento en la distancia entre los lugares de los delitos. Además, si un sospechoso muestra una

preferencia por cometer delitos en condiciones climáticas específicas, ya sean cálidas o frías, esto también puede aumentar la probabilidad de que sea un merodeador. En el modelo de la envolvente convexa, nueve variables contribuyen de manera significativa a la predicción de si un delincuente es un merodeador o un viajero. En cambio, el modelo del círculo contempla cinco variables. Con excepción de las variables relacionadas con el uso de armas, la temporada y el día de la semana, todas las demás tienen un impacto positivo en la probabilidad de clasificación.

En el estudio de Górski (2018), se basa en la investigación realizada en Varsovia sobre la distinción entre merodeadores y viajeros, en relación a los métodos de demarcación del círculo descrito por Canter y Larkin (1993), el estudio plantea la siguiente pregunta;

¿Es posible predecir el tipo de perpetrador (merodeador o viajero) sobre la base de variables espaciales conocidas antes de la detección del perpetrador?

La tipología criminal utilizada en el estudio se basa en delitos de robos, registrados en Varsovia (Polonia). De las 122 series criminales delincuentes analizados, la proporción de viajeros 78,69% y merodeadores 21,31% en robos con la víctima presente y robos cuando la víctima está lejos de sus propiedad (merodeador 32,14% y viajero 67,86%) y, las series varían desde 2 delitos a 9 delitos. Los datos para el análisis se dividieron en categorías de cercanías y merodeador siguiendo una versión modificada del procedimiento descrito por Canter y Larkin (1993).

La metodología utilizada en el estudio de nuevo vuelve a ser una regresión logística en una serie de variables para un conjunto de series de delitos que serían conocidas o que un investigador podría calcular fácilmente. Las variables registradas son las distancias entre eventos y la ubicación aproximada del perpetrador, estas variables se calcularon para cada serie. Estas variables se

denominan distancia entre delitos “*Between Crime*” BC, por sus siglas en inglés, y distancia del trayecto al delito “*Journey To Crime distance*” JTC, por sus siglas en inglés, respectivamente.

Objetivos e hipótesis

Objetivos

El objetivo de este estudio fue ampliar investigaciones previas (Beijsterveldt, 2006; Górski, 2018a; Paulsen, 2007), para determinar el patrón merodeador o viajero respecto a un conjunto de variables asociadas con el perfil geográfico y examinar el desempeño de varias estrategias metodológicas, aplicados a métodos de demarcación descritos por Canter y Larkin (1993) y Warren et al. (1998), que pueda contribuir en el perfilado geográfico con nuevas conclusiones.

El objetivo principal de esta investigación es determinar si sobre la base de las características espaciales y temporales de las series a partir de los incidentes delictivos se puede hacer una estimación si un SHO es un merodeador o viajero.

Realizar una estimación acerca del tipo de delincuente es relevante para el perfil geográfico solo si dicha evaluación se puede fundamentar en la información disponible durante una investigación criminal. Sin embargo, el estado actual de la investigación respecto a los patrones de desplazamiento de los delincuentes aún no ofrece un sustento adecuado para ello.

Para poder alcanzar estos objetivos principales, se presentan los siguientes específicos:

- Identificar, a través de técnicas supervisadas de *machine learning*, variables importantes altamente relacionadas con la respuesta para conseguir una mejor interpretación.

- Analizar dos modelos de perfilado geográfico (Hipótesis del círculo y Envolverte convexa) y encontrar un número pequeño de variables suficientes para una buena predicción de la variable respuesta.
- Obtener una primera idea del rendimiento de algoritmos de *machine learning* aplicados al perfil geográfico.
- Diseño de una plataforma web en el que se puedan introducir valores de las variables y obtener el resultado la clasificación de la tipología delictiva (merodeador o viajero).

Hipótesis

Una vez realizado el planteamiento desarrollado en la primera parte de esta investigación, se formulan la siguiente hipótesis central que guiará el análisis de este capítulo:

1. Utilizando técnicas de aprendizaje automático supervisadas, ¿en qué medida se pueden clasificar a los SHO (merodeador o viajero) para ayudar en la selección o priorización de la realización del perfil geográfico?

Metodo

Se podrían utilizar muchos métodos diferentes de aprendizaje automático para identificar la fuente de un conjunto de datos y clasificarla correctamente. Para nuestros propósitos, elegimos los siguientes:

1. Redes neuronales artificiales (en adelante ANN) es un modelo computacional paralelo compuesto por unidades de procesamiento adaptativo con una alta interconexión en ellas. Estos modelos computacionales utilizan unidades de procesamiento llamadas neuronas que procesan la información recibida a través de

una conexión llamada sinapsis, todo en capas ocultas que finalmente generan una salida de predicción o clasificación.

2. La regresión logística o *Logistic Regression* es un algoritmo de clasificación que se utiliza para predecir la probabilidad de una variable dependiente categórica, es de hecho, de los más utilizados dentro de los de la aprendizaje supervisado, pues son muchas las ocasiones en las que nos encontramos con atributos dicotómicos.

Estos modelos tienen sus orígenes en dos áreas diferentes (estadísticas y ciencias de la computación), pero comparten muchas similitudes. En este capítulo, mostramos que la regresión logística y las redes neuronales artificiales tienen raíces comunes en el reconocimiento de patrones estadísticos, y cómo este último modelo puede verse como una generalización del primero.

Datos

Se ha utilizado una muestra de 84 SHOs (véase datos sobre SHOs en el Anexo A), el número de víctimas osciló entre 4 y 20. De acuerdo con la clasificación del comportamiento de desplazamiento propuesta por (Canter y Larkin, 1993), el 77.6% de los SHOs son merodeadores y el 22.4% son viajeros (véase figura 12-11 y 12).

Para los propósitos de este estudio, el modelo del delincuente fue identificado como merodeador y viajero. El proceso se ha realizado calculando la relación entre la distancia máxima entre los incidentes del crimen y el punto de anclaje del delincuente y la distancia máxima entre los dos incidentes de crimen más alejados utilizando la siguiente ecuación;

$$OffenderModel = \frac{dcr}{dcc} \quad (12.1)$$

donde dcr es la distancia desde el crimen más lejano hasta la residencia del delincuente, y dcc es la mayor distancia entre incidentes criminales. El delincuente fue categorizado como merodeador si la proporción era menor a 1.0, o como viajero si la proporción era igual o mayor a 1.0 (Kent y Leitner, 2007).

En relación con las series, podemos describir como un caso mixto, ya que algunas ubicaciones de los asesinatos de la misma serie se distribuyen fuera del área del círculo y de la envolvente convexa.




Figura 12-12. Distribución variable respuesta: Merodeador/Viajero (Modelo I Rango criminal círculo)




Figura 12-11. Distribución variable respuesta: Merodeador/Viajero (Modelo II Rango criminal convex hull)

Variables

Las variables independientes utilizadas en la tesis doctoral (véase tabla 12-1) se desarrollaron en base a investigaciones realizadas por (Beijsterveldt, 2006; Godwin, 2001; Goodwill et al., 2014; Kocsis, 2007; Kocsis y Irwin, 1997; Laukkanen y Santtila, 2006; Lundrigan y Czarnomski, 2006; Meaney, 2004; Paulsen, 2007; Snook et al., 2005; Warren et al., 1998), teniendo en cuenta las limitaciones y los factores que permiten el cálculo de un perfil geográfico efectivo, se han seleccionado un conjunto de variables relevantes que pueden influir en el comportamiento de los agresores, con la especificidad de centrarse únicamente en los elementos que podrían estar disponibles durante una investigación.

Tabla 12-1

Variabes	Descripción
Variabes Dependientes	
[1] Rango Criminal Círculo	Merodeador (1) El punto de anclaje dentro del rango criminal definido por el círculo. Viajero (0) El punto de anclaje fuera del rango criminal definido por el círculo.
[2] Rango Criminal Envolvente Convexa	Merodeador (1) El punto de anclaje dentro del rango criminal definido por la envolvente convexa. Viajero (0) El punto de anclaje fuera del rango criminal definido por la envolvente convexa.
Variabes Independientes	
[1](X1) Median Distance CMD/Crime	[1] La distancia mediana entre puntos (distancia mediana entre el centro de mínima distancia y el incidente delictivo). (metros)
[2](X2) Average DistanceCMD/Crimes	[2] La distancia media entre puntos (distancia media entre el centro de mínima distancia y el incidente delictivo). (metros)
[3](X3) Maximum DistanceCMD/Crimes	[3] La distancia máxima entre puntos (distancia máxima entre el centro de mínima distancia y el incidente delictivo). (metros)
[4](X4) Minimum DistanceCMD/Crimes	[4] La distancia mínima entre puntos (distancia mínima entre el centro de mínima distancia y el incidente delictivo). (metros)
[6](X6) Spyder Angle CMD /Crimes	[6] Ángulo entre puntos (ángulo entre el centro de mínima distancia y el incidente delictivo). (grados)
[7](X7) Median DistanceCentroide/Crimes	[7] La distancia mediana entre puntos (distancia mediana entre el centroide y el incidente delictivo). (metros)
[8](X8) Average DistanceCentroide/Crimes	[8] La distancia media entre puntos (distancia media entre el centroide y el incidente delictivo). (metros)
[9](X9) Maximum DistanceCentroide/Crimes	[9] La distancia máxima entre puntos (distancia máxima entre el centroide y el incidente delictivo). (metros)
[10](X10) Minimum DistanceCentroide/Crimes	[10] La distancia mínima entre puntos (distancia mínima entre el centroide y el incidente delictivo). (metros)

Variables	Descripción
[11](X11)Spyder Centroide /Crimes	[11] La distancia entre puntos (distancia entre el centroide y el incidente delictivo). (metros)
[12](X12)Spyder Angle Centroide /Crimes	[12] Ángulo entre puntos (ángulos entre el centroide y el incidente delictivo). (grados)
[19] (X19)Mean Interpoint Distance	[19] La distancia media entre cada delito de la serie. (metros)
[20] (X20)Maximum Interpoint Distance	[20] La distancia máxima entre puntos (distancia máxima entre cada delito de la serie). (metros)
[21] (X21)Minimum Interpoint Distance	[21] La distancia mínima entre puntos (distancia mínima entre cada delito de la serie). (metros)
[24] (X24)NNI Value	[24] Valor del índice del vecino más cercano. (clúster) si <1
[25](X25)Distance Venn	[25] Distancia entre los dos puntos Venn más alejados de la serie. (metros)
[26] (X26) Area Venn	[26] Área de la máxima superposición en diagrama Venn. (metros ²)
[29] (X29) Distance Canter	[29] Distancia entre los dos puntos más alejados de la serie. (metros)
[31] (X31) Area Canter	[31] Área del círculo basada en los dos crímenes más lejanos de la serie. (metros ²)
[32](X32) Radio CMD	[32] Radio del área de priorización del centroide aritmético. (metros)
[33] (X33)Area Center Minimum Distance	[33] Área de priorización del centroide aritmético. (metros ²)
[35] (X35) Area of Convex hull	[35] Área de un polígono envolvente convexa de los delitos de cada serie. (metros ²)
[37] (X37)Area Box	[37] Área del rectángulo del cuadrado mínimo alrededor de los lugares de los delitos. (metros ²)
[38] (X38)Intervalo días	[38] Número medio de días entre delitos
[41] (X41)Intensidad	[41] Total de delitos dividido por el total de días de toda la serie de delitos.
[44] (X44)Regularidad	[44] El ritmo de cometer los delitos de los delincuentes, se aplica el coeficiente de variación en un número fijo de días entre los delitos.

Instrumento

Para lograr el método de análisis y las variables dependientes e independientes, se implementó un modelo matemático utilizando el lenguaje de programación Scripting en Python para un entorno QGIS (*QGIS Development Team, 2022*).

Todos los cálculos se realizaron utilizando R, V.4.0.0 (x64) (R Core Team, 2020) (véase código fuente en anexo F).

Aprendizaje automático supervisado

El aprendizaje automático es uno de los campos técnicos de mayor crecimiento en la actualidad y una de las áreas de la ciencia de la computación que más rápidamente se está desarrollando, con aplicaciones enfocadas a la criminología.

Esta disciplina proporciona a los algoritmos la capacidad única de aprender por sí mismos, sin la necesidad de programación explícita. Se asienta en la confluencia de la informática y la estadística, jugando un papel esencial en el universo de la inteligencia artificial. Su enfoque radica en el desafío de diseñar ordenadores que, con el tiempo y la experiencia, optimicen automáticamente su rendimiento. De manera general, el aprendizaje automático se clasifica en dos corrientes: el enfoque predictivo o supervisado y el enfoque descriptivo o no supervisado.

El aprendizaje supervisado es el enfoque predominante de aprendizaje automático que se vamos a emplear en este capítulo. Este escenario puede compararse con el papel de un profesor o supervisor, cuya principal responsabilidad es proporcionar al sistema una medida precisa de su error, que es directamente comparable con los valores de salida esperados. Usando esta información, el sistema ajusta sus parámetros para minimizar el error a través de una función de

pérdida tras cada iteración. En términos sencillos, en el aprendizaje supervisado contamos con variables de entrada (X) y una variable de salida (Y), y seleccionamos un algoritmo para aprender la relación entre estas variables: $Y = f(X)$. Esta relación se define a partir de un conjunto de datos, que consiste en una serie de ejemplos etiquetados $\{(X_i, y_i)\}_{i=1, \dots, n}$. Cada X_i es denominado un vector de características, en el que cada dimensión $i = 1, \dots, D$ representa un aspecto específico del ejemplo. El proceso de aprendizaje culmina cuando el algoritmo alcanza un rendimiento adecuado. No obstante, el objetivo final no solo es aprender la función de mapeo con precisión, sino también asegurarse de que el sistema funcione correctamente con datos nunca vistos. Por ello, es crucial que el modelo tenga la capacidad de generalizar y evite un fenómeno conocido como sobreajuste, tema que se abordará más adelante en esta investigación (Ying, 2019).

Uno de los problemas más comunes en los modelos de aprendizaje automático es sobreentrenar nuestro modelo con datos conocidos para que se ajuste lo más posible a nuestro conjunto de datos, pero que falle al predecir situaciones distintas a las del entrenamiento. Una buena práctica para evitar “*overfitting*” es dividir nuestro conjunto de datos en aquellos que utilizaremos para entrenar y en aquellos que usaremos para testear los modelos.

El conjunto de datos se ha dividido en dos sub-conjuntos disjuntos: se utilizó el 80% de los datos para entrenar los algoritmos y ajustar los hiperparámetros, mientras que el 20% restante se reservó para la validación. Una vez obtenido el modelo final, se utilizaron estos datos para estimar el error de predicción. En primer lugar, el conjunto de entrenamiento se empleó como hasta ahora para entrenar cada uno de los diferentes modelos. Para cada uno de estos, mediremos su desempeño con el conjunto de datos de prueba. De esta forma, al ser observaciones sobre las que no se había

entrenado el modelo, podemos obtener una aproximación del desempeño real que tendría cada uno de los diferentes modelos.

Modelo de regresión logística

Para poder determinar la eficiencia de los modelos construidos con herramientas de aprendizaje automático se generó primero un modelo de regresión logística. Este modelo serviría como referencia para comprobar si los algoritmos de *machine learning* eran capaces de generar modelos superiores al conseguido con una técnica clásica, utilizados en los trabajos de modelización de distribución de la tipología delictiva (Górski, 2018; Paulsen, 2007; Van Der Kemp, 2014).

La regresión logística binaria, o para variables de respuesta dicotómica, es un tipo de modelo lineal generalizado (GLM de las siglas en inglés de *Generalized Linear Models*) frecuentemente utilizado para modelar la probabilidad de ocurrencia de un suceso en función de una serie de variables predictoras (Hosmer y Lemeshow, 2000). Para ajustar el modelo en R, se ha utilizado la función *glm*, en un intento de identificar el "mejor subconjunto" de variables predictoras para utilizarlo en un modelo de regresión logística binaria.

La función de regresión logística está diseñada para denotar una probabilidad que estará entre los valores de 0 y 1 independientemente de la magnitud de z , ya que puede variar desde infinito negativo (-) al infinito positivo (+).

Podemos expresar el modelo de la función de regresión logística como:

$$f(x) = \frac{1}{1 + e^{-z}} \quad (12.2)$$

El modelo de regresión logística calcula la probabilidad de la respuesta seleccionada como función de los valores de las variables predictoras.

La fórmula es la siguiente:

$$z = \alpha + \beta_1 x_1 + \beta_2 x_2 \dots \beta_k x_k \quad (12.3)$$

Las probabilidades en el ejemplo son la probabilidad de ser merodeador ($P_{\text{merodeador}}$) dividida por la probabilidad de ser viajero (P_{viajero}). Una probabilidad tiene un rango de 0 (la probabilidad de ser viajero) a infinito (la probabilidad de ser merodeador es 1).

$$\ln \frac{P_{\text{merodeador}}}{P_{\text{viajero}}} = a + b_1 X_1 + b_2 X_2 + \dots \quad (12.4)$$

También podemos convertir el modelo logístico en un modelo de probabilidad. La posibilidad de que el delincuente sea un merodeador:

$$P_{\text{merodeador}} = \frac{e^{(a+b_1 X_1 + a + b_2 X_2 + \dots)}}{e^{(a+b_1 X_1 + a + b_2 X_2 + \dots)} + 1} \quad (12.5)$$

Y la posibilidad de que el delincuente sea un viajero es:

$$P_{\text{viajero}} = \frac{1}{e^{(a+b_1 X_1 + a + b_2 X_2 + \dots)} + 1} \quad (12.6)$$

En el campo de la estadística, la regresión logística, también conocida como regresión *logit*, se categoriza como un modelo probabilístico de clasificación estadística (Bishop, 2006). El propósito principal de la regresión logística, es analizar y dilucidar las relaciones existentes entre una variable dependiente y una o más variables independientes. En otras palabras, busca determinar la existencia de una relación entre la variable respuesta y las variables explicativas, identificar el signo de dicha relación si está presente, y calcular la probabilidad de ocurrencia de un evento definido, calculando en los valores de las variables explicativas. Este método se utiliza ampliamente para modelar la probabilidad de un resultado binario en función de diversas características predictoras.

Para construir el modelo de regresión logística, se utilizó la función *step* del paquete *stats* de R (R Core Team, 2020). Este algoritmo hace parte de los procedimientos *stepwise* ejecutados de forma descendiente (Guerrero, 2016), en particular, este algoritmo parte del conjunto de todas las variables predictoras y determina en cada paso (cada ejecución del GLM), la variable que menos aporta al modelo en función del criterio de información Akaike (en adelante AIC), y la elimina; este proceso de eliminación lo realiza hasta que eliminar alguna de las variables ya no disminuye el AIC del modelo.

En ocasiones, nos encontramos en la incertidumbre de saber qué variables pueden ser relevantes para nuestro modelo. En estos escenarios, una estrategia puede ser introducir todas las variables disponibles y utilizar el método *stepwise* para seleccionar de manera rápida y eficiente entre ellas. Todo método paso a paso se fundamenta en un algoritmo que evalúa la relevancia de las variables en el modelo, incluyéndolas o excluyéndolas conforme a una regla preestablecida. En este contexto, se considera como variable más importante aquella que genera el cambio más

significativo en un criterio denominado AIC el cual se deriva del *deviance* y del número de parámetros del modelo. El proceso inicia ajustando el modelo con solo la constante y comparándolo con el modelo resultante de introducir cada una de las variables; la variable que da lugar a un valor de AIC menor es considerada la más relevante e introduciéndose en el modelo. Posteriormente, el modelo con esta variable se compara con los modelos resultantes de introducir adicionalmente otras variables, y así sucesivamente. Además, en cada etapa se verifica que la variable añadida en el paso anterior mantiene su significatividad. Las iteraciones sucesivas van eliminando los predictores estadísticamente menos significativos hasta que todos los valores de p sean inferiores a 0,05, lo que indica que la inclusión de esa variable representa una mejora significativa en el criterio AIC.

Modelo Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (en adelante ANN) son capaces de aproximar cualquier relación funcional compleja, sin necesidad de preespecificar el tipo de relación entre covariables y variables de respuesta, a diferencia de los Modelos Lineales Generalizados (en adelante GLM) (McCullagh y Nelder, 1983). Estas redes, inspiradas en la estructura neuronal del cerebro humano, buscan aprender estructuras de datos mediante algoritmos adaptativos, con un enfoque en identificar patrones emergentes y una mínima intervención humana. A pesar de haber sido conceptualizadas hace décadas (McCulloch y Pitts, 1943), las ANN han ganado relevancia en campos enfocados en la exploración de datos. Diversos estudios han implementado ANN para tareas como pronosticar puntos de alta concentración de delitos y detectar patrones criminales

(Zhuang et al., 2017; Dahbur y Muscarello, 2003). Dada su versatilidad, se considera una herramienta estadística valiosa, siendo recomendadas para clasificar delincuentes mediante variables específicas (English, 2008; Paulsen, 2007). Actuando como extensiones directas de GLM, las ANN adaptan iterativamente sus parámetros, utilizando datos observados para aprender una aproximación de la relación.

Nuestro segundo enfoque aplica un modelo de redes neuronales para ajustar el modelo en R (R Core Team, 2020), se ha utilizado el paquete *neuralnet* (Günther y Fritsch, 2010) que contiene una función muy flexible para entrenar redes neuronales de retroalimentación, es decir, para aproximar una relación funcional en la situación anterior. Teóricamente puede manejar un número arbitrario de covariables y variables de respuesta, así como de capas y neuronas ocultas a pesar de que el cálculo.

El propósito del modelo ANN es predecir un resultado objetivo utilizando datos de entrada a través de un algoritmo de aprendizaje de retropropagación Rrop “*resilient backpropagation*” (Igel y Hüsken, 2003).

Las redes neuronales artificiales son agrupaciones de perceptrones. Para las redes alimentadas hacia adelante de múltiples capas, la salida es...

$$O_N = \frac{1}{1+e^{-(\beta \cdot o_H + \beta_0)'}} \quad (12.7)$$

y esta salida se toma como $P(1|x, \beta, \beta_0, \alpha)$. Aquí, o_H es un vector de salidas del perceptrón, cada uno con sus propios parámetros α ; estos perceptrones se suelen llamar neuronas ocultas. Debido a la no linealidad en estas neuronas ocultas, la salida O_N de una red neuronal artificial es

una función no lineal de las entradas. En un contexto de clasificación, esto significa que la frontera de decisión también puede ser no lineal, lo que hace al modelo más flexible en comparación con la regresión logística.

El paquete *neuralnet* permite la posibilidad de seleccionar entre diversas opciones: la retropropagación tradicional, la retropropagación resistente con retroceso de pesos (Riedmiller, 1994) o sin este (Riedmiller y Braun, 1993), así como la versión modificada y globalmente convergente desarrollada por Anastasiadis et al. (2005). Cada uno de estos algoritmos busca minimizar la función de error, incorporando una tasa de aprendizaje a los pesos que se mueven en dirección contraria al gradiente.

En contraste con el algoritmo de retropropagación tradicional, la retropropagación resistente (*rprop+* y *rprop -* se refieren a la retropropagación resiliente con y sin retroceso de probabilidad de peso)

El algoritmo de retropropagación resistente se fundamenta en el algoritmo de retropropagación tradicional, cuyo objetivo principal es modificar los pesos de una red neuronal para localizar un mínimo local de la función de error. Así, se calcula el gradiente de la función de error (dE/dw) en relación con los pesos, con el fin de identificar una raíz. De manera específica, los pesos se ajustan en dirección contraria a las derivadas parciales, proceso que continúa hasta alcanzar un mínimo local. Esta idea fundamental se representa de manera esquemática en la figura 12-13 para una función de error univariante.




Figura 12-13. Idea básica del algoritmo de retropropagación ilustrada para una función de error univariada $E(w)$. Tomado de *Neuralnet: Training of neural networks* (p.32) por Günther y Fritsch, 2010

Si la derivada parcial es negativa, el peso aumenta (parte izquierda de la figura); si la derivada parcial es positiva, el peso disminuye (parte derecha de la figura). Esto garantiza que se alcance un mínimo local. Todas las derivadas parciales se calculan utilizando la regla de la cadena, dado que la función calculada de una red neuronal es, en esencia, una composición de funciones de integración y activación.

Este algoritmo identifica el esquema de ponderación óptimo a través de un proceso iterativo en el que los pesos se cambian gradualmente a través de un proceso de propagación hacia adelante y hacia atrás (Rumelhart *et al.* 1986 ; Lek y Guégan 2000).

Este algoritmo utiliza el signo (positivo o negativo) del gradiente para mostrar la dirección del peso de ajuste. Mientras que el tamaño del cambio, los pesos se determinan mediante el ajuste de valor (0). Solo el signo de la derivada puede determinar la dirección de la actualización del peso. La propagación resiliente tiene parámetros de entrenamiento, pero es extremadamente extraño que sea necesario cambiarlos de sus valores predeterminados. Esto hace que la

propagación resiliente sea una forma muy fácil de utilizar un algoritmo de entrenamiento (Prasad et al., 2013).

Entrenar un modelo de red neuronal requiere identificar los pesos óptimos que definen las conexiones entre las capas del modelo. Los pesos óptimos son aquellos que minimizan el error de predicción para un conjunto de datos de prueba que es independiente del conjunto de datos de entrenamiento. El entrenamiento se logra utilizando el algoritmo de aprendizaje de retropropagación Rrop (*resilient backpropagation*) (Igel y Hüsken, 2003).

Estructura

Investigamos el potencial predictivo de las redes neuronales dentro del marco de la *Range Criminal Circle* (en adelante RCC) y *Range Convex Hull Polygon* (en adelante RCH). Nuestra metodología adopta un proceso estructurado que abarca desde la búsqueda de datos, pasando por su preprocesamiento, hasta el diseño y evaluación de los modelos.

En concreto, se crearon ocho modelos de redes neuronales, cada uno con arquitecturas y estrategias de preprocesamiento únicas para examinar los efectos en el rendimiento de la predicción.

La metodología para desarrollar y evaluar ocho modelos de redes neuronales para predecir RCC y RCH comprende un enfoque sistemático. Los modelos están diseñados con variaciones en la arquitectura y la estandarización de características para explorar su impacto en el rendimiento de la predicción.

Con objetivo de optimizar el aprendizaje de la red se lleva a cabo una estandarización de los datos. Esta variable estandarizada, ampliamente utilizada en estadística para comparar datos

de diferentes muestras, se define como el número de desviaciones típicas que un valor específico tiene con la relación a la media de la muestra.

El uso de esta técnica facilita la focalización y reducción de las variables en el espacio, posibilitando comparaciones que son independientes de la unidad de medida. De esta manera, se pueden omitir los valores absolutos de estas variables y enfocarse exclusivamente en las diferencias relativas entre ellas, que es donde reside la información verdaderamente relevante.

Cada modelo se construye cuidadosamente y sus predicciones se evalúan rigurosamente utilizando varias métricas. Los resultados de este estudio proporcionarán información valiosa sobre la eficacia de las redes neuronales en la predicción de RCC y RCH, así como la influencia de la arquitectura y la estandarización de características en el rendimiento del modelo.

Cada uno de estos primeros cuatro modelos se sometió a una evaluación rigurosa, que incluyó métricas como la precisión, el error cuadrático medio y las curvas de precisión-recuperación. La evaluación tuvo como objetivo evaluar las capacidades predictivas de las redes neuronales bajo diferentes condiciones, considerando tanto la presencia como la ausencia de estandarización.

- Modelo 1 (Modelo RCC)

El primer modelo de red neuronal tenía como objetivo predecir el RCC utilizando una arquitectura simple. Para la creación de redes neuronales artificiales no existe un número correcto de capas ocultas ni de número de neuronas, por lo tanto, optamos por esta regla, para establecer una línea de base para el rendimiento.

En este estudio, se utilizó un tipo de red de retropropagación de retroalimentación de dos capas.

La topología de diseño:

- 26 neuronas en la capa de entrada (una por cada una de las variables)
- 2 neuronas en la capa de salida (1) merodeador o (0) viajero
- 1 capa ocultas de 1 neurona

Como puede verse en la figura 12-14, cada conexión (flechas negras) está asociada a un peso; pero las conexiones asociadas a los sesgos (flechas azules) también están especificadas pesos.

El modelo 1 tenía dos objetivos asociados. El objetivo principal era predecir el RCC directamente a partir de las entidades de entrada. Sin embargo, el segundo objetivo introdujo una variación al predecir el RCC después de aplicar la estandarización (min-máx) a los datos de entrada. La estandarización (mín.-máx) escala las entidades de entrada a un rango específico, normalmente entre 0 y 1.




Figura 12-14. Estructura de la artificial neural network construida.

- Modelo 2 (Modelo RCC) con estandarización.

El modelo 2 siguió una arquitectura similar a la del modelo 1, pero se centró únicamente en la predicción de RCC. Sin embargo, introdujo la estandarización de las entidades de entrada. La estandarización implica escalar las entidades para que tengan una media de 0 y una desviación estándar de 1. Este paso adicional tenía como objetivo evaluar el impacto de la estandarización de características en la predicción de RCC, particularmente en términos de mejora de la convergencia y el rendimiento del modelo.

- Modelo 3 (Modelo RCH) sin estandarización.

En el tercer modelo, el conjunto de datos se preprocesó de manera diferente. El modelo 3 tuvo como objetivo predecir el RCH sin aplicar estandarización a las características de entrada. Al omitir este paso de estandarización, el modelo buscó examinar cómo los datos sin procesar influían en las predicciones. La arquitectura sigue siendo la misma que en los modelos anteriores, con una sola capa oculta que contiene un nodo.

- Modelo 4 (Modelo RCH) con estandarización.

El modelo 4 conservó la arquitectura del modelo 3, pero introdujo la estandarización de características en los datos de entrada. Este modelo tuvo como objetivo explorar el impacto de la estandarización en la predicción de RCH similar al modelo 2 para RCC. Se aplicó la estandarización de características para determinar si podía mejorar el rendimiento del modelo y la convergencia del proceso de entrenamiento.

Las secciones siguientes de la metodología proporcionarán explicaciones detalladas de los cuatro modelos de redes neuronales restantes, abarcando sus arquitecturas, variables objetivo y pasos de preprocesamiento de datos. Esta visión integral de la metodología es esencial para comprender las complejidades del proceso de investigación y los factores que influyen en el rendimiento y los resultados de los modelos de redes neuronales. El enfoque sistemático de la metodología garantiza una exploración exhaustiva de las predicciones de RCC y RCH, allanando el camino para obtener información significativa y aplicaciones potenciales en diversos campos.

Al igual que los modelos anteriores, los modelos 5 a 8 se someten a un exhaustivo proceso de evaluación. Se emplean varias métricas, como la precisión, el error cuadrático medio y las curvas de precisión-recuperación, para evaluar el rendimiento predictivo de cada modelo en

diferentes condiciones. Esta evaluación proporciona información valiosa sobre la eficacia de diferentes arquitecturas y la influencia de la estandarización de características en la precisión de la predicción.

- Modelo 5 (Modelo RCC).

El modelo 5 marca un cambio en la arquitectura en comparación con los modelos anteriores (véase figura 12-15). Esta mayor complejidad se introduce para permitir que el modelo capture patrones y relaciones más intrincados dentro de los datos, que pueden no estar representados adecuadamente por una capa oculta de un solo nodo.

En este estudio, se utilizó un tipo de red de retropropagación de retroalimentación de dos capas.

La topología de diseño:

- 26 neuronas en la capa de entrada (una por cada una de las variables)
- 2 neuronas en la capa de salida (1 merodeador o (0) viajero)
- 2 capa ocultas (la primera capa consta de cinco neuronas, mientras que la segunda capa contiene tres neuronas)




Figura 12-15. Estructura de la artificial neural network construida (5,3)

- Modelo 6 (Modelo RCC) capas ocultas (5,3) con estandarización.

El modelo 6 continúa prediciendo el RCC, pero agrega estandarización de características a los datos de entrada. Mantiene la arquitectura introducida en el modelo 5, que incluye dos capas ocultas con cinco y tres neuronas, respectivamente. Al incluir la estandarización de características, este modelo tiene como objetivo explorar si el escalado de los datos de entrada puede mejorar el rendimiento de la predicción, de forma similar a los modelos 2 y 4.

- Modelo 7 (Modelo RCH) capas ocultas (5,3) sin estandarización.

El modelo 7 cambia el enfoque a la predicción del RCH. Conserva la arquitectura del primer modelo, que consiste en una sola capa oculta con un nodo. Sin embargo, la variable objetivo difiere, ya que este modelo tiene como objetivo descubrir patrones y relaciones relacionados con RCH, sin aplicar estandarización a las entidades de entrada.

- Modelo 8 (Modelo RCH) capas ocultas (5,3) con estandarización.

El modelo final, el modelo 8, comparte el mismo marco arquitectónico que el modelo 7, pero introduce la estandarización de características en los datos de entrada. Este modelo tiene como objetivo examinar el impacto de la estandarización en la predicción del casco de rango, similar a los modelos 2 y 6. La estandarización de características se aplica para evaluar si puede mejorar las capacidades predictivas del modelo para RCH.

Entrenamiento de redes neuronales

La implementación del modelo basado en RNN se realizó en R (R Core Team, 2020) mediante el paquete “*neuralnet*”. Esta librería fue desarrollada por Fritsch et al. (2019).

La función *neuralnet*, se utiliza para entrenar una red neuronal, facilita la definición del número de capas y neuronas ocultas requeridas, según la complejidad deseada del modelo. Es fundamental mencionar que la complejidad de la función calculada se incrementa con la adición

de más capas o neuronas ocultas. Por defecto, la configuración establece una sola capa oculta con una neurona oculta. A continuación, se detallan los argumentos más significativos de esta función:

- *hidden*, un vector que especifica el número de capas y neuronas ocultas en cada capa.
- *rep*: número de repeticiones del proceso de entrenamiento (5)
- *Algoritmo*: cadena que contiene el tipo de algoritmo. Los valores posibles son "backprop", "rprop+", "rprop-", "sag" o "slr". "backprop" se refiere a la retropropagación tradicional, "rprop+" y "rprop-" se refieren a la retropropagación resistente con y sin retroceso de peso y "sag" y "slr" se refieren al algoritmo globalmente convergente modificado (gr-prop), en la investigación "rprop+"
- *err.fct*, una función de error diferenciable. Se pueden utilizar las cadenas "sse" y "ce", que hacen referencia a 'suma de errores al cuadrado' y 'entropía cruzada'. Por defecto: "sse"
- *act.fct*, una función de activación diferenciable. Las cadenas "logistic" y "tanh" son posibles para la función logística y la tangente hiperbólica. Por defecto: "logistic".

El número de neuronas de la capa oculta se determina en función de la siguiente ecuación:

$$\begin{aligned}
 \text{neuralnet}(\text{fórmula} = \text{"Commuter + Maraude ~."}, \text{hidden} = c(5,3), \text{umbral} = \\
 0.01, \text{stepmax} = 1e + 05, \text{rep} = 5, \text{lifesign.step} = 1000, \text{algoritmo} = \text{"rprop +"}, \\
 \text{err.fct} = \text{"sse"}, \text{act.fct} = \text{"logistic"}, \text{linear.output} = \\
 \text{TRUE}, \text{constantes.weights} = \text{NULL}, \text{verosimilitud} = \text{FALSE}) \quad (12.8)
 \end{aligned}$$

Herramienta “GEO-SCRIPT”

Para estudiar la eficacia de las distintas estrategias de elaboración de perfiles, se ha desarrollado la aplicación, denominada GEO-SCRIPT (Salafranca, 2023), un programa basado en un entorno WEB que permite *explorar* las capacidades predictivas de las redes neuronales en el contexto *Circle Theory of Environmental Range* y *Convex Hull Polygon*, realizando una valoración para determinar si un SHO es viajero o merodeador en cada serie.

GEO-SCRIPT simplifica el uso del software de elaboración de perfiles geográficos de dos maneras. En primer lugar, los investigadores pueden utilizar la aplicación en cualquier sistema operativo siempre que dispongan de conexión a Internet. En segundo lugar, GEO-SCRIPT se actualiza en una ubicación central, en el servidor WEB. Como resultado, los usuarios no tienen que descargar e instalar una nueva versión de la aplicación con cada nueva actualización. Se pueden corregir errores y añadir funciones sin el tiempo y el esfuerzo necesarios para distribuir la nueva versión.

Además, GEO-SCRIPT se ha diseñado con una interfaz de usuario sencilla (véase figura 12-16a). La pantalla se divide en tres partes principales: (1) una columna a la izquierda contiene la lista de opciones de red neuronal, modelo de rango y opción de estandarización y (2) una gran área a la izquierda contiene las variables y campos para introducir los valores (véase figura 12-16). Un área en la parte derecha de la pantalla muestra la salida del diagrama de nodos de red neuronal (véase figura 12-16b) y en la parte inferior derecha el resultado de la predicción (merodeador o viajero) y una serie de métricas de evaluación del modelo (véase figura 12-16c). GEO-SCRIPT también se diseñó con un flujo de trabajo simplificado.

El usuario comienza haciendo clic en el enlace "*choose model*" de la cabecera de la aplicación e introduciendo un modelo de red neuronal (monocapa o multicapa). A continuación, el usuario añade la tipología de rango a examinar haciendo clic en el enlace "*choose variable*" y se selecciona la pestaña "*select parameter*" accediendo a una lista de variables de la serie a examinar. Una vez introducidas los parámetros solicitados, se selecciona la pestaña "*submit parameters*". Finalmente se obtiene el resultado de la predicción y una serie de métricas de evaluación del modelo (véase figura 12-16c).

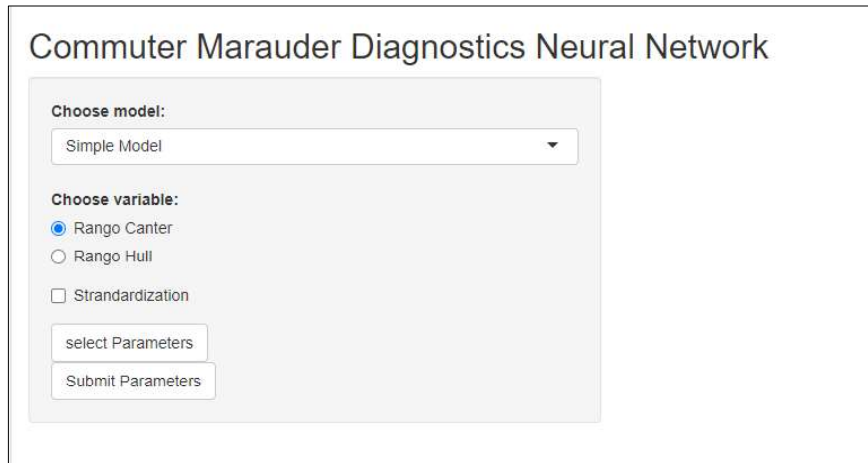


Figura 12-16a. Visualizador WEB GEO-SCRIPT

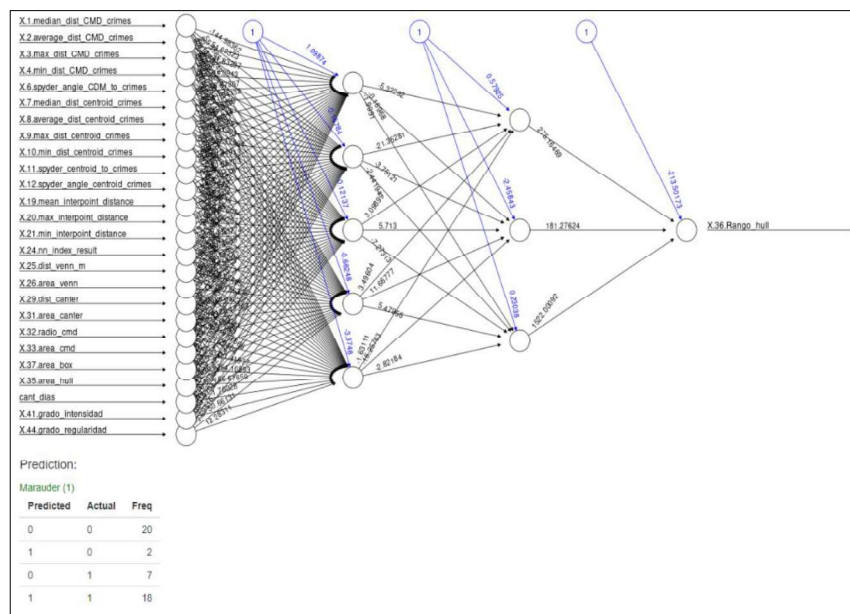


Figura 12-6b. Salida del diagrama de Nodos de red neuronal

[7]median_dist_centroid_crimes	903099	Prediction: Marauder (1) <table border="1"> <thead> <tr> <th>Predicted</th> <th>Actual</th> <th>Freq</th> </tr> </thead> <tbody> <tr> <td>0</td> <td>0</td> <td>20</td> </tr> <tr> <td>1</td> <td>0</td> <td>2</td> </tr> <tr> <td>0</td> <td>1</td> <td>7</td> </tr> <tr> <td>1</td> <td>1</td> <td>18</td> </tr> </tbody> </table> Confusion Matrix and Statistics <pre> Reference Prediction 0 1 0 20 7 1 2 18 Accuracy : 0.8085 95% CI : (0.6674, 0.9085) No Information Rate : 0.5319 P-Value [Acc > NIR] : 7.498e-05 Kappa : 0.6206 McNemar's Test P-Value : 0.1824 Sensitivity : 0.9091 Specificity : 0.7200 Pos Pred Value : 0.7407 Neg Pred Value : 0.9000 Prevalence : 0.4681 Detection Rate : 0.4255 Detection Prevalence : 0.5745 Balanced Accuracy : 0.8145 'Positive' Class : 0 </pre>	Predicted	Actual	Freq	0	0	20	1	0	2	0	1	7	1	1	18
Predicted	Actual		Freq														
0	0		20														
1	0		2														
0	1		7														
1	1		18														
[8]average_dist_centroid_crimes	904849																
[9]max_dist_centroid_crimes	1325581																
[10]min_dist_centroid_crimes	856570																
[11]spyder_centroid_to_crimes	945399																
[12]spyder_angle_centroid_crimes	180																
[19]mean_interpoint_distance	1208844																
[20]max_interpoint_distance	1821084																
[21]min_interpoint_distance	735475																
[24]nn_index_result	21																
[25]dist_venn_m																	

Figura 12-4c. Introducción de parámetros e interpretación diagnóstico Merodeador o Viajero

Métricas de evaluación

Tras implementar algoritmos de aprendizaje automático, es esencial contar con herramientas que nos permitan evaluar su eficacia. A estas herramientas se les conoce como métricas de evaluación del rendimiento. Existen múltiples métricas desarrolladas en la investigación, y cada una se enfoca en diferentes aspectos del desempeño de un algoritmo. Por ello, es crucial seleccionar el conjunto de métricas más adecuado para cada problema específico de aprendizaje automático. En este capítulo, exploramos diversas métricas predominantes para tareas de clasificación, con el objetivo de obtener perspectivas detalladas sobre la eficiencia de los algoritmos y llevar a cabo un análisis comparativo.

1. Exactitud (*Accuracy*)

La forma más sencilla de medir el rendimiento de un clasificador es utilizar la métrica exactitud. Aquí, comparamos la clase real y prevista de cada punto de datos, y cada coincidencia cuenta para una predicción correcta.

La variable *accuracy* es la tasa total de aciertos con las predicciones, es decir, número de elementos clasificados correctamente.

Es la más utilizada y quizá la primera opción para evaluar el rendimiento de un algoritmo en problemas de clasificación. A pesar de su uso generalizado, la exactitud no es la métrica de rendimiento más adecuada en algunas situaciones, especialmente en los casos en los que las clases de variables objetivo del conjunto de datos están desequilibradas.

2. Sensibilidad (*Recall o sensitivity*)

La sensibilidad (*sensitivity*) es la probabilidad de clasificar un elemento como la clase positiva y que realmente pertenezca a la clase positiva. La sensibilidad se calcula como la proporción de casos positivos que obtuvieron un resultado positivo en la predicción. También se conoce como tasa de verdaderos positivos (TPR) o recuperación. La sensibilidad se utiliza para evaluar el rendimiento del modelo porque nos permite ver cuántas instancias positivas el modelo pudo identificar correctamente. Un modelo con alta sensibilidad tendrá pocos falsos negativos, lo que significa que le faltan algunos de los casos positivos. En varios casos de uso, es importante que los modelos tengan una alta sensibilidad porque queremos que nuestros modelos puedan encontrar todos los casos positivos para poder hacer predicciones precisas.

3. Especificidad (*Specificity*)

La especificidad mide la proporción de verdaderos negativos que el modelo identifica correctamente. Esto implica que habrá otra proporción de negativos reales que se predijeron como positivos y podrían denominarse falsos positivos. Una especificidad alta significa que el modelo identifica correctamente la mayoría de los resultados negativos, mientras que una especificidad baja significa que el modelo etiqueta erróneamente muchos resultados negativos como positivos.

4. Valor Predictivo Positivo (PPV)

Es una métrica clave en las tareas de clasificación, ya que mide la proporción de casos positivos verdaderos entre todas las instancias clasificadas como positivas por el modelo. Es crucial comprender cuán confiable es una clasificación positiva.

5. Valor Predictivo Negativo (VAN)

Es una métrica importante en las tareas de clasificación, ya que mide la proporción de casos negativos verdaderos entre todas las instancias clasificadas como negativas por el modelo. Es crucial para comprender qué tan confiable es una clasificación negativa.

6. Prevalencia (*Prevalence*)

En este contexto, la prevalencia se refiere a la proporción de casos positivos (ya sea RCC o RCH) presentes en el conjunto total de datos (el número de verdaderos positivos dividido por el número total de observaciones). Es importante tener en cuenta que la prevalencia no es una medida del rendimiento del modelo, sino una característica del propio conjunto de datos. Sin embargo, proporciona un contexto importante para comprender las otras métricas de rendimiento, ya que el equilibrio de clases puede afectar significativamente al rendimiento aparente de un modelo.

7. Tasa de detección

La tasa de detección, a menudo sinónimo de "tasa de verdaderos positivos" o "recuperación", es un indicador clave de rendimiento en las tareas de clasificación. Mide la proporción de casos positivos reales que fueron identificados correctamente como tales por el modelo. Esta métrica es crucial para comprender la capacidad del modelo para detectar casos positivos dentro del conjunto de datos.

8. Prevalencia de detección

La prevalencia de detección se refiere a la proporción de casos que fueron predichos como positivos por el modelo, independientemente de si estas predicciones fueron correctas o no. Esta

métrica ayuda a comprender la inclinación del modelo hacia la predicción de casos positivos, lo que puede ser particularmente informativo cuando se compara con la prevalencia real.

9. Precisión equilibrada

La precisión equilibrada es un promedio de sensibilidad (tasa positiva verdadera) y especificidad (tasa negativa verdadera), que se ajusta a cualquier desequilibrio en las clases positivas y negativas del conjunto de datos. Es especialmente útil en escenarios en los que las clases están desequilibradas y la precisión tradicional puede dar una visión engañosamente optimista del rendimiento del modelo.

10. Kappa de Cohen

Las métricas actuales más populares y extendidas incluyen el kappa de Cohen (J.Cohen, 1960) desarrollado originalmente para probar la confiabilidad entre evaluadores, en las últimas décadas el kappa de Cohen ingresó a la comunidad de aprendizaje automático para comparar el desempeño de los clasificadores.

El estadístico Kappa, o Kappa de Cohen, mide el nivel de concordancia entre las predicciones del modelo y los valores reales, al tiempo que se ajusta la concordancia que se produce al azar. Un valor Kappa de 1 indica muy buena concordancia, mientras que un valor de 0 indica una concordancia pobre. Los valores negativos indican un acuerdo menor que el azar, lo que implica un desacuerdo sistemático.

Resultados

La calidad de los resultados obtenidos con estos modelos depende principalmente de tres factores: la calidad del conjunto de datos utilizado en la construcción del modelo, el cuidado con el que se eligieron los parámetros ajustables del modelo y los criterios de evaluación utilizados para informar los resultados del proceso de modelado. Es imperativo que estos detalles estén presentes en las investigaciones que utilizan modelado predictivo, ya que de lo contrario la validez de las afirmaciones en los artículos no puede ser evaluada. Por lo tanto, analizamos en detalle el proceso de construcción de modelos de regresión logística y modelos de redes neuronales, y señalamos qué factores deben ser considerados al juzgar resultados de investigación utilizando modelos predictivos (Saleh y Layous, 2022).

Estos modelos proporcionan una forma funcional f y un vector de parámetros a para expresar $P(y|x)$ como $P(y|x) = f(x;a)$.

Los parámetros α se determinan en función del conjunto de datos D , generalmente mediante la estimación de máxima verosimilitud. Dado que la forma funcional de f difiere para la regresión logística y las redes neuronales artificiales, la primera se conoce como un método paramétrico, mientras que la segunda a veces se llama semi-paramétrica o no paramétrica. Esta distinción es importante porque la contribución de los parámetros en la regresión logística (coeficientes e intercepción) puede ser interpretada, mientras que este no siempre es el caso con los parámetros de una red neuronal (pesos).

Regresión Logística

Nuestro primer enfoque aplica la función *glm* de R en un intento de identificar el "mejor subconjunto" de variables predictoras para utilizarlo en un modelo de regresión logística binaria.

Una aplicación inicial de la función hizo uso de las 26 variables predictoras, aplicó la selección hacia atrás a través del método "logit" y usó el criterio de información de Akaike (AIC) sobre la calidad relativa del modelo estadístico para un conjunto de datos, produciendo el subconjunto de variables que arroja la cifra de AIC (414.2) más baja de todas las posibles combinaciones de nuestros predictores en el modelo I de [Hipótesis del Círculo], siendo las variables más relevantes:

[35]area_hull,[29]dist_canter,[31]area_canter,[24]nn_index_result,[20]max_interpoint_distance,[7]median_dist_centroid_crimes,[33]area_cmd,[37]area_box, [9]max_dist_centroid_crimes (véase fichas variables).

```
Step: AIC=414.2
`[30]rango_canter` ~ `[7]median_dist_centroid_crimes` + `[9]max_dist_centroid_crimes` +
  `[11]spyder_centroid_to_crimes` + `[12]spyder_angle_centroid_crimes` +
  `[20]max_interpoint_distance` + `[21]min_interpoint_distance` +
  `[24]nn_index_result` + `[25]dist_venn_m` + `[29]dist_canter` +
  `[31]area_canter` + `[33]area_cmd` + `[37]area_box` + `[35]area_hull`

<none>                Df Deviance    AIC      LRT Pr(>Chi)
- `[12]spyder_angle_centroid_crimes`  1   388.4   414.4    2.2 0.1354474
- `[11]spyder_centroid_to_crimes`    1   390.3   416.3    4.1 0.0426476 *
- `[21]min_interpoint_distance`     1   394.0   420.0    7.8 0.0052921 **
- `[25]dist_venn_m`                 1   396.3   422.3   10.1 0.0015139 **
- `[35]area_hull`                   1   397.8   423.8   11.6 0.0006536 ***
- `[29]dist_canter`                 1   400.2   426.2   14.0 0.0001792 ***
- `[31]area_canter`                 1   405.1   431.1   18.9 1.377e-05 ***
- `[24]nn_index_result`             1   418.9   444.9   32.7 1.070e-08 ***
- `[20]max_interpoint_distance`     1  8866.7  8892.7  8480.5 < 2.2e-16 ***
- `[7]median_dist_centroid_crimes`  1  9587.6  9613.6  9201.4 < 2.2e-16 ***
- `[33]area_cmd`                   1 10380.6 10406.6 9994.4 < 2.2e-16 ***
- `[37]area_box`                   1 10524.7 10550.7 10138.5 < 2.2e-16 ***
- `[9]max_dist_centroid_crimes`    1 12615.3 12641.3 12229.1 < 2.2e-16 ***
---
```

Figura 12-5. Modelo I [Hipótesis del Círculo], Significatividad de las variables seleccionadas por el modelo de reducción del AIC.

y un AIC (486.3) para el modelo II de la [Envolvente convexa]. El resultado de la ejecución inicial fue un modelo compuesto por 13 variables predictoras para ambos modelos y con métricas de rendimiento como se indica en la figura 12-20, siendo las variables más relevantes: [24]nn_index_result, [21]min_interpoint_distance, [8]average_dist_centroid_crimes, [19]mean_interpoint_distance, [31]area_canter, [29]dist_canter, [33]area_cmd, [37]area_box (véase ficha variables).

```
Step: AIC=486.26
`[36]Rango_hull` ~ `[1]median_dist_CMD_crimes` + `[4]min_dist_CMD_crimes` +
`[8]average_dist_centroid_crimes` + `[10]min_dist_centroid_crimes` +
`[19]mean_interpoint_distance` + `[21]min_interpoint_distance` +
`[24]nn_index_result` + `[26]area_venn` + `[29]dist_canter` +
`[31]area_canter` + `[33]area_cmd` + `[37]area_box` + `[44]grado_regularidad`

<none>                Df Deviance    AIC    LRT Pr(>Chi)
- `[4]min_dist_CMD_crimes`      1  460.7  486.3    2.5 0.1170265
- `[44]grado_regularidad`      1  461.1  487.1    2.8 0.0949710 .
- `[10]min_dist_centroid_crimes` 1  461.6  487.6    3.3 0.0677614 .
- `[26]area_venn`                1  463.4  489.4    5.1 0.0233958 *
- `[1]median_dist_CMD_crimes`   1  463.6  489.6    5.4 0.0204865 *
- `[24]nn_index_result`         1  471.1  497.1   12.8 0.0003478 ***
- `[21]min_interpoint_distance` 1  471.4  497.4   13.2 0.0002861 ***
- `[8]average_dist_centroid_crimes` 1  471.6  497.6   13.4 0.0002555 ***
- `[19]mean_interpoint_distance` 1  472.6  498.6   14.3 0.0001556 ***
- `[31]area_canter`             1  474.1  500.1   15.8 7.029e-05 ***
- `[29]dist_canter`            1  475.7  501.7   17.4 2.963e-05 ***
- `[33]area_cmd`               1  481.6  507.6   23.3 1.396e-06 ***
- `[37]area_box`               1 14273.3 14299.3 13815.0 < 2.2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Figura 12-6. Modelo II [Envolvente convexa]. Significatividad de las variables seleccionadas por el modelo de reducción del AIC

Un parámetro con signo positivo se asocia, en regresión logística a un OR (*Odds Ratio*) mayor que la unidad, es decir a un factor cuya presencia aumenta la probabilidad del evento de interés, en este caso merodeador. Análogamente se considerarán los parámetros con signo negativo como factores atenuantes

En cuanto a las medidas de bondad del ajuste, se debe tener en cuenta que para los casos particulares del GLM, modelos *Logit* y *Probit*, no tiene sentido utilizar el criterio del R^2 ya que por lo general este criterio es una medida que expresa el ajuste del modelo y en la regresión logística lo que se busca es una buena clasificación. El análisis de regresión logística no produce una proporción de la varianza explicada R^2 , como se define para las variables de intervalo o razón en un modelo lineal. Sin embargo, existen diferentes pseudo-medidas de R^2 , que son comparables al R^2 del análisis de regresión lineal. En este caso, se ha obtenido el de Cox y Snell con un valor 0.352 en el modelo I [Hipótesis del Círculo], y un valor 0.168 en el Modelo II [Envolvente convexa]. Este coeficiente toma valores entre 0 y 1 de forma que 0 indicaría un efecto muy bajo de las variables independientes, mientras que en las proximidades de 1 mostraría un efecto considerable. El R^2 de Nagelkerke, que es el valor del R^2 de Cox y Snell estandarizado sobre el valor máximo que éste podría tomar. De esta forma se garantiza que se pueda interpretar su valor entre 0 y 1. El valor obtenido en este caso, ha sido en el Modelo I [Hipótesis del Círculo] =0.470 de R^2 , señala un ajuste similar que han tenido nuestros datos, comparados con el estudio de Paulsen (2007), obteniendo un valor= 0.489 de R^2 de Nagelkerke. En el modelo II [Envolvente convexa], se ha obtenido un valor 0.231 de R^2 de Nagelkerke.

El pseudo- r^2 de Mc Fadden proporciona una indicación del rendimiento del modelo, pero generalmente tiene valores mucho más bajos que el OLS r^2 . Para un modelo *probit* de 1000 observaciones, Veall y Zimmermann (1996), encontraron que un OLS r^2 de 0.5 fue asociado con un Mc Fadden r^2 de 0.25. Para la regresión logística, un valor entre 0.2 y 0.4 es considerado como un ajuste excelente (McFadden, 1978), en nuestro modelo I [Hipótesis del Círculo] se ha obtenido un valor de 0.314 y en el modelo II [Envolvente convexa], un valor de 0.141.

Tabla**12-2***Modelo de predicción Modelo I [Hipótesis del Círculo] y modelo II [Envolvente convexa].*

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Variables	Modelo I [Hipótesis círculo]		Modelo II [Envolvente convexa]	
	Coefficiente B	Exp (B)	Coefficiente B	Exp (B)
[1]median_dist_CMD			-2.185482e-05	0.03237572 *
[4]min_dist_CMD_			-1.343187e-05	0.131701180
[7]median_dist_centroid_	-1.138026e-04	-7.5540738 *		
[8]average_dist_centroidD			-2.179854e-04	0.0030929 **
[9]max_dist_centroid_	-1.324239e-04	-12.1773148**		
[10]min_dist_centroid_			3.213347e-05	0.084813392
[11]spyder_centroid_to	-1.298305e-05	-1.0660623		
[12]spyder_angle_centroid_	-1.808006e-03	-0.1031389		
[19]mean_interpoint_distan			1.411895e-04	0.00265327 **
[20]max_interpoint_distanc	1.206725e-04	18.6061795 *		
[21]min_interpoint_distanc	-2.168312e-05	-1.2838687 *	-4.16703e-05	0.002962304 **
[24]nn_index_result	-6.768513e-01	-0.979853***	-3.239376e-01	0.001260239 **
[25]dist_venn_	1.818021e-05	1.3977093**		
[26]area_venn			-1.155136e-12	0.491386444
[29]dist_canter	2.281079e-05	3.2437098**	1.643359e-05	0.001128457 **
[31]area_canter	-2.648936e-11	-663.9022***	-1.821418e-11	0.018490506 *
[33]area_cmd	1.243007e-11	3472.8797176	2.332342e-14	0.512585352
[37]area_box	1.084339e-13	1.6188314	6.184964e-14	0.652095443
[35]area_hull	-1.190302e-10	-1.7048243 *		
[44]grado_regularidad			4.657778e-01	0.099083453

La proporción de la varianza explica el modelo (es decir, la devianza)

$$D^2 = (\text{Devianza modelo nulo} - \text{Deevianza residual}) / (\text{Devianza modelo nulo}) \cdot 100 \quad ()$$

En este caso la *devianza* modelo I [Hipótesis del Círculo] explica el 31.42% de la variabilidad

En este caso la *devianza* modelo II [Envolvente convexa], explica el 14.11% de la variabilidad

Para evaluar si el modelo logístico es válido, se analiza tanto el modelo en su conjunto como los predictores que lo forman. El modelo se considerará útil si es capaz de mejorar la predicción de las observaciones respecto al modelo nulo sin predictores. Para ello se analiza la significancia de la diferencia “*Deviance*” de residuos entre ambos modelos “*Null deviance*” y “*Residual deviance*”, con un estadístico que sigue la distribución chi-cuadrado con grados de libertad correspondientes a la diferencia de los grados de libertad de ambos modelos.

Null deviance: 563.14 on 406 degrees of freedom
Residual deviance: 386.20 on 393 degrees of freedom

Para saber la eficacia del modelo prediciendo la variable respuesta utilizamos el estadístico chi-cuadrado, que mide la diferencia entre el modelo en su estado actual y el modelo cuando sólo se incluyó la constante.

Tabla 12-3

Valores de log-likelihood, AIC, Chisq para los modelos I y II

Modelo	Df.diff	LogLik.diff	Chisq	p.value	AIC
I [Hipótesis Círculo]	-13	-88.469	176.94	7.15E-31	414.2
II [Envolvente Convexa]	-13	-37.649	75.297	8.3796e-11	486.2

Es importante también analizar el porcentaje de predicciones correctas además de los falsos positivos y falsos negativos que hace nuestro modelo para evaluar su potencial. Se ha utilizado un *threshold* de 0.5. Si la probabilidad predicha de que el valor del mercado sea positivo es mayor de 0.5, la observación se asignará al nivel 1 “Up”, y si es menor se asignará al nivel 0 “Down”. Además de evaluar la prueba-error global, es conveniente identificar como se reparte este error entre falsos positivos y falsos negativos, ya que puede ocurrir que un modelo sea mucho mejor prediciendo en una dirección que en otra. Esto se ve directamente influenciado por límite de clasificación o *threshold* establecido.

A partir de la tabla de clasificación, que relaciona los casos observados con los pronosticados, podemos obtener distintas medidas de la capacidad predictiva del modelo.




Figura 12-7 [ROC-Hipótesis del círculo]




Figura 12-8 [ROC-Envolvente convexa]

Tabla 12-4

Matriz Confusión Modelo I [Hipótesis Círculo] Modelo II [Envolvente Convexa]

Medidas	Modelo I [Hipótesis Círculo]	Modelo II [Envolvente Convexa]
Accuracy	0.7549	0.6932
Sensitivity	0.7600	0.8788
Specificity	0.7500	0.4167
Precision	0.7451	0.7342
Negative Predictive	0.7647	0.6522
False Positive Rate	0.2500	0.5833
False Discovery Rate	0.2549	0.2658
False Negative Rate	0.2400	0.1212
F1 Score	0.7525	0.8000

La primera medida que podemos establecer es el porcentaje de casos que el modelo predice perfectamente, aquéllos que pronostica como negativos y son efectivamente negativos (A) y

aquellos que pronostica como positivos y son efectivamente positivos (D). El porcentaje correcto para nuestros datos será de 75.49% en el modelo I [Hipótesis Círculo] y 69.3% en el modelo II [Envolverte Convexa]. La sensibilidad del modelo se refiere a la capacidad que tiene éste para detectar como positivos los casos que poseen la característica, obteniendo unos resultados para el modelo I [Hipótesis Círculo] de 76.00% y de 87.88% en el modelo II [Envolverte Convexa]. La especificidad del modelo se refiere a la capacidad que tiene éste para discriminar correctamente los casos que no poseen la característica, obteniendo unos resultados para el modelo I [Hipótesis Círculo] de 75.00% y de 41,67% en el modelo II [Envolverte Convexa].

Tabla**12-5***Éxito de predicción logística*

Tipología	Viajero	Merodeador	%correcto	Viajero	Merodeador	%correcto
	[I]	[I]	[I]	[II]	[II]	[II]
Viajero	38	13	74.5%	58	21	73.4%
Merodeador	12	39	76.4%	8	15	65.2%
Precisión			75.4%			69.3%

[I] [Hipótesis Círculo] [II] [Envolverte Convexa].

El modelo I [Hipótesis Círculo] obtiene buena capacidad predictiva al tener valores altos tanto de sensibilidad como de especificidad, por el contrario, el modelo II [Envolverte Convexa] obtiene valores bajos en la sensibilidad.

En primer lugar, vamos a mostrar el *logit* del modelo I [Hipótesis Círculo], simplemente como el logaritmo del Odd (en regresión logística se emplea siempre el logaritmo neperiano o de base “e”).

Los valores estimados de los coeficientes del modelo I [Hipótesis Círculo]:

$$\begin{aligned}
 \text{logit}(p) &= \log(p/(1-p)) \\
 &= 1.223 - 0.0001138 * [7]\text{median_dist_centroid_crimes} - 0.0001324 \\
 &\quad * [9]\text{max_dist_centroid_crimes} - 0.00001298 \\
 &\quad * [11]\text{spyder_centroid_to_crimes} - 0.001808 \\
 &\quad * [12]\text{spyder_angle_centroid_crimes} + 0.0001207 \\
 &\quad * [20] \text{max_(\textit{interpoint_distance})} \\
 &\quad * -0.00002168 [21] \text{min_(\textit{interpoint_distance})} * -0.6769 \\
 &\quad * [24]\text{nn_(\textit{index_result})} + 0.00001818 * [25]\text{dist_(\textit{venn_m})} + 0.00002281 \\
 &\quad * [29]\text{dist_canter} - 0.00000000002649 * [31]\text{area_canter} \\
 &\quad + 0.00000000001243 * [33]\text{area_cmd} + 0.0000000000001084 \\
 &\quad * [37]\text{area_box} - 0.000000000119 * [35]\text{area_hull}
 \end{aligned}
 \tag{12.9}$$

Los valores estimados de los coeficientes del modelo II [Envolvente convexa]:

$$\begin{aligned}
 \text{logit}(p) &= \log(p/(1-p)) \\
 &= -0.4573 - 0.00002185 * [1]\text{median_dist_CMD_crimes} - 0.00001343 \\
 &\quad * [4]\text{min_dist_CMD_crimes} - 0.000218 \\
 &\quad * [8]\text{average_dist_centroid_crimes} + 0.00003213 \\
 &\quad * [10]\text{min_dist_centroid_crimes} + 0.0001412 \\
 &\quad * [19]\text{mean_interpoint_distance} - 0.00004167 \\
 &\quad * [21]\text{min_interpoint_distance} - 0.3239 * [24]\text{nn_index_result} \\
 &\quad - 0.00000000001155 * [26]\text{area_venn} + 0.00001643 * [29]\text{dist_canter} \\
 &\quad - 0.00000000001821 * [31]\text{area_canter} + 0.0000000000002332 \\
 &\quad * [33]\text{area_cmd} + 0.00000000000006185 * [37]\text{area_box} + 0.4658 \\
 &\quad * [44]\text{grado_regularidad}
 \end{aligned}
 \tag{10}$$

La siguiente ecuación representa las variables utilizadas para determinar la probabilidad basado en la interacción de los predictores observados

Siendo p la probabilidad de que el individuo tome el valor “1” Merodeador en la variable dicotómica.

Al cociente $(p/(1 - p))$ se le conoce como odds ratio. Por tanto, los coeficientes del modelo logit se interpretan como el logaritmo del odds ratio.

Una forma de facilitar la interpretación de los coeficientes es exponenciando (*Exp B*), (véase tabla 12-2). Para analizar el valor de diferentes variables en la predicción, es más fácil leer los índices de probabilidad $Exp(B)$ (Bijleveld y Commandeur, 2012). En este caso, las probabilidades de merodeador se dividen por la posibilidad de un viajero. Las variables que contribuyen significativamente a la predicción de si un delincuente es merodeador o viajero (véase tabla 12-6 y 7).

Podemos inferir lo siguiente de los coeficientes enumerados anteriormente en el modelo I

[Hipótesis Círculo]:

$logit(p)[[24]nn_index_result + 1] - logit(p)[[24]nn_index_result] = -0.6769$ al exponenciar el coeficiente (Exp B)

$$\frac{\exp(logit(p)[[24]nn_index_result + 1] - logit(p)[[24]nn_index_result])}{\exp(log(p/(1 - p)[[24]nn_index_result + 1]) - \exp(log(p/(1 - p)[[24]nn_index_result]))} = 0.5081899 \quad (12.11)$$

Podemos decir que para un aumento de 1 unidad en la variable $[24] nn_index_result$, esperamos ver una disminución de aproximadamente un 49.18% ($1 - 0.5081899 = 0.4918101$) en la cuota de merodeador, este 49.18% no depende del valor que tengan $[24] nn_index_result$.

Y en el modelo II [Envolvente convexa]:

Podemos examinar el efecto en un aumento de 1 unidades en $[24] nn_index_result$

$$\frac{\exp(logit(p)[[24]nn_index_result + 1] - logit(p)[[24]nn_index_result])}{\exp(-0.3239376)} \quad (12.12)$$

Podemos decir que el coeficiente para [24] *nn_index_result* es la diferencia en las probabilidades logarítmicas, para 1 unidad de aumento en [24] *nn_index_result*, el cambio esperado en las probabilidades logarítmicas es -0.3239376

$$\exp(\text{logit}(p)[[24]nn_(\text{index_result}) + 1] - \text{logit}(p)[[24]nn_(\text{index_result})]) = \frac{\exp(\log(p/(1-p)[[24]nn_(\text{index_result}) + 1]))}{\exp(\log(p/(1-p)[[24]nn_(\text{index_result})])} = 0.7232954 \quad (12.13)$$

Podemos decir que para un aumento de 1 unidad en la variable [24] *nn_index_result*, esperamos ver una disminución de aproximadamente un 27,67% ($1 - 0.7232954 = 0,2760$) en la cuota de merodeador, este 27.67% no depende del valor que tengan [24] *nn_index_result*.

Según el modelo [Hipótesis Círculo] resultante, las variables [24]*nn_index_result* y [31]*area_canter* son los predictores estadísticamente significativas (31) ($\beta_1 = -2.65E-11$, *p-value* = 0.000323) y (24) ($\beta_1 = -6.77E-01$, *p-value* = 1.24E-06). Su valor positivo indica que, por cada unidad que se incrementa la variable (31) y (24), se espera que el logaritmo de odds de la variable merodeador se incremente en promedio 0.000323 y 1.24E-06 unidades respectivamente.

Podemos decir que para un aumento de 1 unidad en la variable [24] *nn_index_result*

$\text{logit}(p)[[24]nn_(\text{index_result}) + 1] - \text{logit}(p)[[24]nn_(\text{index_result})] = -0.6769$ al exponenciar el coeficiente (Exp B)

$$\exp(\text{logit}(p)[[24]nn_(\text{index_result}) + 1] - \text{logit}(p)[[24]nn_(\text{index_result})]) = \frac{\exp(\log(p/(1-p)[[24]nn_(\text{index_result}) + 1]))}{\exp(\log(p/(1-p)[[24]nn_(\text{index_result})])} = 0.5081899$$

(12.4)

, esperamos ver una disminución de aproximadamente un 49,18% ($1 - 0.5081899 = 0.4918101$) en la cuota de merodeador, este 49,18% no depende del valor que tengan [24] `nn_index_result`

En el modelo I [Hipótesis Círculo] las categorías [24] y [31] influyen fuertemente en la predicción. Cinco variables contribuyen significativamente a la predicción de si un sospechoso es un merodeador o un viajero [9], [25], [29]. La probabilidad de que un sospechoso sea un merodeador aumenta cuanto [20] [25] [29] [33] [37]. La probabilidad de que el sospechoso sea un merodeador disminuye a medida que aumenta las unidades en las siguientes variables [7],[9],[11],[12],[21],[24],[31],[35].

Tabla 12-6

Método de predicción modelo I [Hipótesis Círculo]

Variables	B-coeficiente	Exp(B)	Porcen.	Tipología
[7]median_dist_centroid_	-1.14E-04	0.9998862	0.011	Commuter
[9]max_dist_centroid_	-1.32E-04	0.9998676	0.013	Commuter
[11]spyder_centroid_to_	-1.30E-05	0.999987	0.001	Commuter
[12]spyder_angle_centroid_	-1.81E-03	0.9981936	0.181	Commuter
[20]max_interpoint_distance`	1.21E-04	1.0001207	0.012	Marauder
[21]min_interpoint_distance`	-2.17E-05	0.9999783	0.002	Commuter
[24]nn_index_result`	-6.77E-01	0.5082147	49.179	Commuter
[25]dist_venn_m`	1.82E-05	1.0000182	0.002	Marauder
[29]dist_canter`	2.28E-05	1.0000228	0.002	Marauder
[31]area_canter`	-2.65E-11	1	0	Commuter
[33]area_cmd`	1.24E-11	1	0	Marauder
[37]area_box`	1.08E-13	1	0	Marauder
[35]area_hull`	-1.19E-10	1	0	Commuter

En el modelo II [Envolvente Convexa] las categorías [8],[19], [21],[24],[29] influyen en la predicción. Cinco variables contribuyen significativamente a la predicción de si un sospechoso es un merodeador o un viajero La probabilidad de que un sospechoso sea un merodeador aumenta cuanto [10] [19] [29] [33] [37] [44]. La probabilidad de que el sospechoso sea un merodeador disminuye a medida que aumenta las unidades en las siguientes variables [1],[4],[8],[21],[24],[26],[31].

Tabla 12-7

Método de predicción Modelo II (Envolvente Convexa)

	B-coeficiente	Exp(B)	Porcen	Tipología
[1]median_dist_CMD	-2.19E-05	0.9999781	0.002	Commuter
[4]min_dist_CMD	-1.34E-05	0.9999866	0.001	Commuter
[8]average_dist_centroid_	-2.18E-04	0.999782	0.022	Commuter
[10]min_dist_centroid_	3.21E-05	1.0000321	0.003	Marauder
[19]mean_interpoint_distance	1.41E-04	1.0001412	0.014	Marauder
[21]min_interpoint_distance	-4.17E-05	0.9999583	0.004	Commuter
[24]nn_index_result`	-3.24E-01	0.7232954	27.67	Commuter
[26]area_venn	-1.16E-12	1	0	Commuter
[29]dist_canter	1.64E-05	1.0000164	0.002	Marauder
[31]area_cante	-1.82E-11	1	0	Commuter
[33]area_cm`	2.33E-14	1	0	Marauder
[37]area_box	6.18E-14	1	0	Marauder
[44]grado_regularidad	4.66E-0	1.5932529	59.325	Marauder

Redes Neuronales

Una herramienta esencial para validar las predicciones del modelo es la matriz de confusión (véase figura 12-21). Esta matriz ofrece una representación clara del desempeño del clasificador, proporcionando una visión concisa sobre su precisión y eficacia. En esta matriz, las columnas

denotan la cantidad real de elementos en cada categoría, mientras que las filas reflejan el número de predicciones para dichas categorías.

En cualquier modelo de aprendizaje automático, normalmente nos centramos en la precisión. Pero si se trata de un problema de clasificación, también debe preocuparse por el porcentaje de clasificación correcta y clasificación errónea. Por lo tanto, necesitamos un mecanismo que no solo proporcione precisión, sino que también ayude a estimar la clasificación correcta y la clasificación errónea.

La matriz de confusión sirve para este propósito. Es una matriz $N \times N$ que ayuda a evaluar el rendimiento del modelo de aprendizaje automático para problemas de clasificación, donde N es el número de clases objetivo. La matriz compara los valores objetivo-reales con los predichos por el modelo de aprendizaje automático.

El modelo de clasificación predice la clase de cada instancia de datos, atribuyendo a cada muestra su etiqueta prevista (positiva o negativa): así, al final del procedimiento de clasificación, cada muestra se encuentra en uno de los cuatro casos siguientes casos (véase figura 12-21):

- Los positivos reales que son positivos predichos correctamente se denominan verdaderos positivos (TP);
- Los positivos reales que son negativos predichos erróneamente se denominan falsos negativos (FN);
- Los negativos reales que se predicen correctamente negativos se denominan verdaderos negativos (TN);

- Los negativos reales que son positivos predichos erróneamente se denominan falsos positivos (FP)

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negative (TN)	False Positive (FP) Type I Error
	Positive +	False Negative (FN) Type II Error	True Positive (TP)

Figura 12-9. Matriz Confusión (Problema de clasificación binaria) matriz 2 x 2 Nota: Adaptado de Medium, por Suresh, 2020, (<https://medium.com/analytics-vidhya/what-is-a-confusion-matrix-d1c0f8feda5>)

- Desarrollo de Modelos y Evaluación
 - Modelo 1 [Red monocapa de un solo nodo] (RCC)

El primer modelo de red neuronal de esta serie es bastante simplista, con una sola capa oculta con un nodo. A pesar de su simplicidad, esta arquitectura tiene la ventaja de ser sencilla, lo que reduce el riesgo de sobreajuste, especialmente cuando se trata de un conjunto de datos que comprende 27 variables. Este modelo está diseñado para predecir el RCC sin ningún tipo de estandarización de datos, manteniendo así la escala y distribución originales de las características de los datos.

La elección de usar un solo nodo en la capa oculta puede parecer demasiado simple, pero es crucial comprender que esto podría funcionar bien si RCC se puede separar linealmente en función de las características proporcionadas. Sin embargo, la falta de estandarización podría

introducir sesgos si las características originales varían en escalas, ya que las redes neuronales son sensibles a las escalas de datos de entrada.




Figura 12-10. Matriz de confusión modelo 1 (conjunto de datos de entrenamiento)

La matriz de confusión para el modelo simple entrenado en la variable RCC sin estandarización muestra un número sustancial de Verdaderos Positivos (TP) y Falsos Positivos (FP), lo que indica una tendencia a predecir la clase positiva. Con 239 TP y 28 Verdaderos Negativos (TN), el modelo parece eficaz para identificar la clase positiva, pero lo hace a expensas de una alta tasa de FP (238), lo que sugiere una sobrepredicción de la etiqueta “merodeador”. El FN bajo (8) indica que rara vez pasa por alto los casos positivos. Sin embargo, el equilibrio necesita mejorar, potencialmente a través del ajuste del umbral o abordando el desequilibrio de clase, ya

que tiene dificultades para identificar correctamente las instancias de “viajero”, con el riesgo de un alto error de Tipo I.

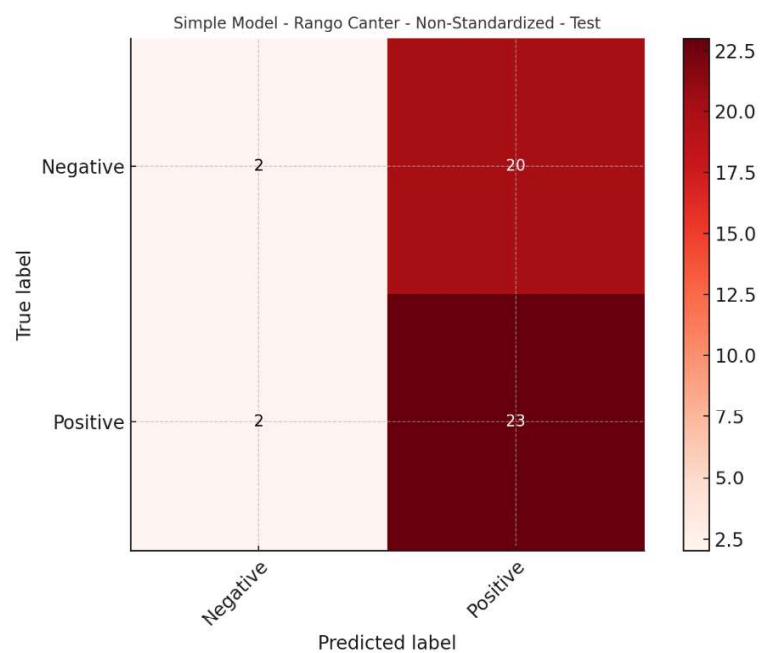


Figura 12-11. Matriz de confusión modelo 1 (conjunto de datos de prueba)

En el conjunto de pruebas, el modelo demuestra características similares, con un alto TP (23) pero también una alta tasa de FP (20), lo que indica un sobreajuste hacia la predicción de la clase "merodeador". El TN es muy bajo (2), lo que revela la continua lucha del modelo para identificar correctamente las instancias de "viajero". Con solo 2 FN, el modelo captura eficazmente la mayoría de los casos positivos, pero necesita una mejora significativa en la generalización para reducir el error de Tipo I, particularmente en la distinción entre las dos clases.

- Modelo 2 [Red de un solo nodo y una sola capa] Predicción RCC con estandarización (min/max).

El modelo 2 refleja la arquitectura del modelo 1, con la distinción fundamental de implementar la estandarización mínima-máxima en las entidades de entrada. Al cambiar el escalado de las características de los datos a una escala común, el modelo mejora la uniformidad de las diferentes características, lo que puede conducir a un proceso de aprendizaje más equilibrado e imparcial.

La implementación de la estandarización (min/max) es fundamental, especialmente en los modelos de redes neuronales, ya que normalmente acelera el entrenamiento y puede conducir a un mejor rendimiento. Para un objetivo como RCC, que podría verse influenciado por entidades de diferentes escalas, la estandarización garantiza que el único nodo de la capa oculta no se vea indebidamente influenciado por entidades con escalas más grandes.

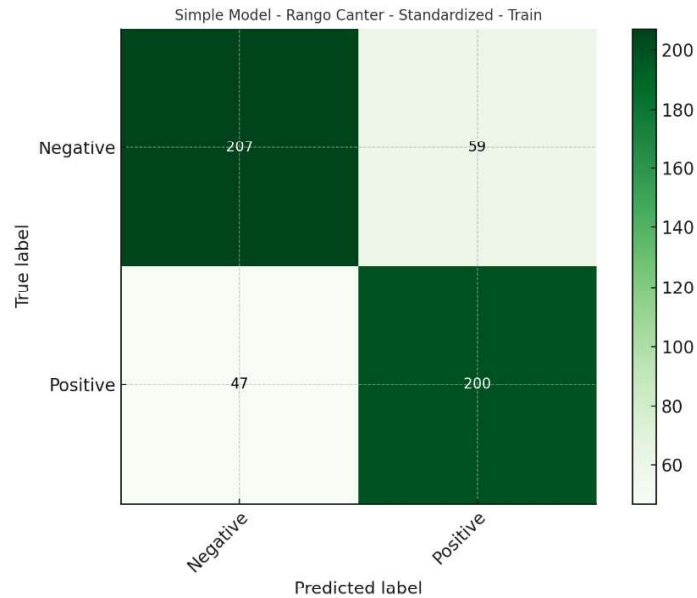


Figura 12-12. Matriz de confusión modelo 2 (conjunto de datos de entrenamiento)

La estandarización mejora drásticamente el rendimiento. El TP disminuyó a 200 y el TN aumentó a 207, mostrando una predicción más equilibrada entre clases. FP se redujo significativamente a 59, reduciendo el error Tipo I. Sin embargo, el FN aumentó a 47, lo que sugiere que se pasaron por alto algunos casos positivos. El modelo se volvió más conservador en la predicción de "merodeador", mejorando su capacidad para distinguir entre clases, aunque a expensas de algunas predicciones positivas fallidas (error de Tipo II).

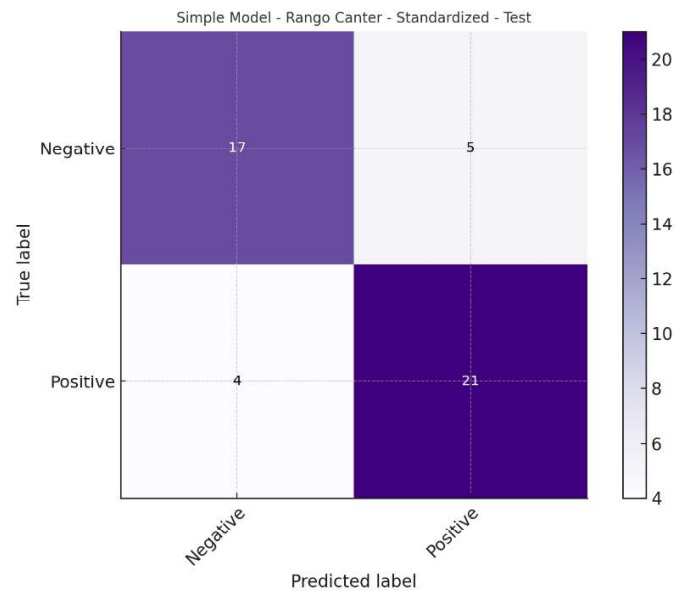


Figura 12-13. Matriz de confusión modelo 2 (conjunto de datos de prueba)

El conjunto de pruebas muestra una mejora constante con la estandarización. El equilibrio entre TP (21) y TN (17) es mejor, y la reducción sustancial en FP (5) indica que menos instancias de "viajero" se clasifican incorrectamente. Sin embargo, un aumento en FN (4) muestra un ligero aumento en los errores de Tipo II. La generalización del modelo ha mejorado, lo que demuestra el impacto positivo de la estandarización en el rendimiento del modelo, aunque se debe prestar atención al FN ligeramente más alto.

- Modelo 3 [Red de un solo nodo y una sola capa] (predicción RCH sin estandarización mínima- máxima)

El modelo 3, que mantiene la consistencia de la arquitectura, tiene como objetivo predecir el RCH sin estandarización de datos. La predicción de RCH introduce una nueva variable objetivo, y es fundamental analizar qué tan bien funciona un modelo de red neuronal simple con la escala original de características.

El rendimiento de este modelo da una idea de la separabilidad del RCH en función de las características proporcionadas. Si RCH tiene relaciones no lineales con las características, la simplicidad de este modelo puede presentar limitaciones. Además, la ausencia de estandarización podría no ser un problema (si todas las características están en escalas similares) o un inconveniente significativo (si las escalas de características varían ampliamente).




Figura 12-14. Matriz de confusión modelo 3 (conjunto de datos de entrenamiento)

El modelo cuando se entrena en la variable RCH sin estandarización, exhibe un comportamiento marcadamente diferente en comparación con la variable RCC. El modelo predice la clase negativa (viajero) con mayor frecuencia, como lo demuestra un alto número de Verdaderos Negativos (TN = 305), pero tiene dificultades significativas con la clase positiva (merodeador), lo que lleva a un alto número de Falsos Negativos (FN = 157). Las bajas tasas de Verdaderos Positivos (TP = 29) y relativamente bajas de Falsos Positivos (FP = 22) sugieren que el modelo es conservador en la predicción de la clase positiva, posiblemente debido al desequilibrio de clases o a la naturaleza de las características de los datos de RCH que afectan el aprendizaje del modelo.

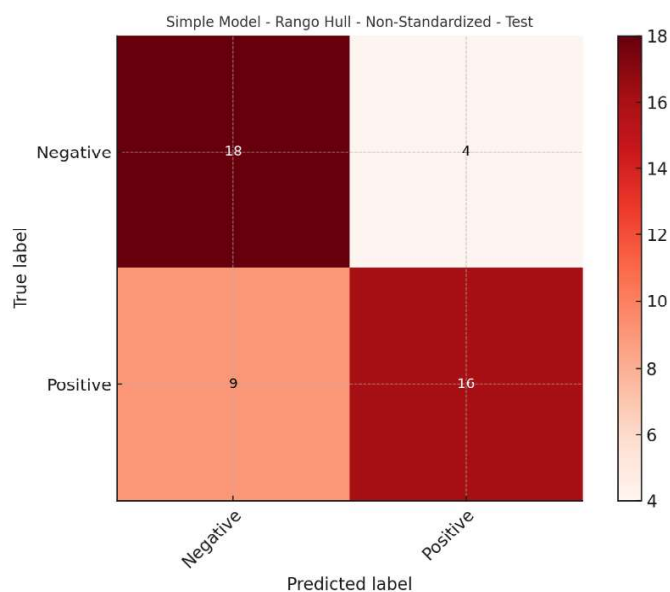


Figura 12-15. Matriz de confusión modelo 3 (conjunto de datos de prueba)

Este conservadurismo continúa en el conjunto de pruebas, ya que el modelo mantiene una alta tasa de TN (18) pero tiene dificultades para identificar correctamente los casos positivos (TP

= 16), junto con un número considerable de FN (9). La baja tasa de FP (4) confirma la vacilación del modelo a la hora de predecir la clase positiva. Esto indica una fuerte presencia de errores de Tipo II, donde el modelo pasa por alto instancias de la clase "merodeador", lo que sugiere la necesidad de recalibración o reentrenamiento con un enfoque en la sensibilidad a la identificación positiva de la clase.

- Modelo 4 [Red de un solo nodo y una sola capa] (Predicción RCH con estandarización mínima- máxima)

El modelo 4 incorpora la estandarización (min/max) al tiempo que mantiene la arquitectura de una sola capa de un solo nodo, esta vez dirigida a RCH. Se espera que las características estandarizadas proporcionen un entorno más propicio para que el modelo aprenda, dada la escala uniforme de los datos.

Con la introducción de la estandarización, se espera que este modelo supere a su predecesor si las variaciones de escala entre las características obstaculizaban previamente el rendimiento. La efectividad de este modelo dependerá en gran medida de cómo se relacione RCH con las características estandarizadas. Sin embargo, aquí se aplican las mismas limitaciones que con los otros modelos de un solo nodo: si RCH tiene relaciones complejas y no lineales con las características, este modelo puede tener dificultades para capturarlas.

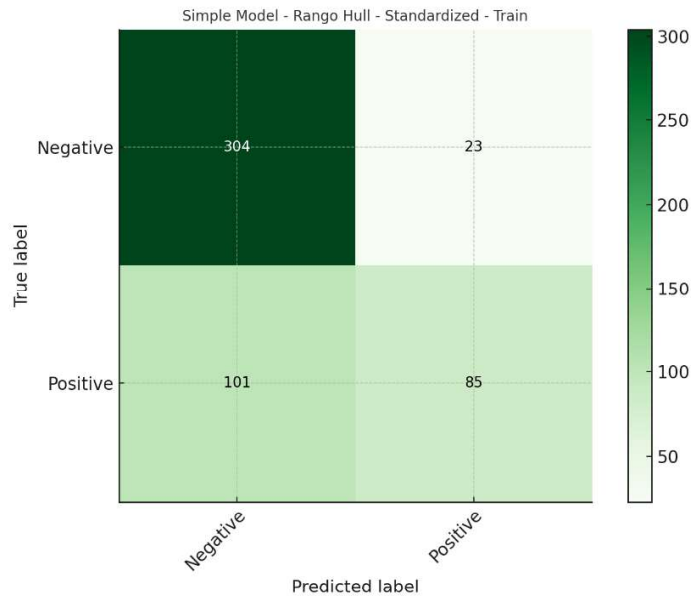


Figura 12-16. Matriz de confusión modelo 4 (conjunto de datos de entrenamiento)

La introducción de la estandarización mejora el rendimiento del modelo, especialmente con predicciones positivas (TP aumentado a 85). Hay un equilibrio notable entre TP y TN (304), lo que indica predicciones de clase más precisas. La PF sigue siendo baja (23), mostrando una especificidad mantenida. Sin embargo, todavía hay un número sustancial de FN (101), lo que indica que las predicciones positivas no se cumplieron, aunque se redujeron con respecto al modelo no estandarizado. Esta mejora sugiere que el escalado de características proporcionado por la estandarización ayuda al modelo a interpretar mejor la variabilidad del conjunto de características y mejora su capacidad predictiva para la clase positiva.




Figura 12-17. Matriz de confusión modelo 4 (conjunto de datos de prueba)

El conjunto de datos de prueba refleja las mejoras en el entrenamiento, con una mejor tasa de TP (9) y una excelente especificidad (FP baja = 1, TN alta = 21). Sin embargo, la alta tasa de FN (16) indica que el modelo todavía pasa por alto un número significativo de casos positivos. Si bien la estandarización mejora el rendimiento del modelo, particularmente en la especificidad, requiere un mayor ajuste para abordar los altos errores de Tipo II que continúan, probablemente a través de métodos que mejoran la sensibilidad, como el ajuste del umbral de clasificación o el uso de técnicas de sobremuestreo para abordar el posible desequilibrio de clase.

- Modelo 5 [Red de dos capas] (Predicción RCC sin estandarización)

El modelo 5 marca un alejamiento de la arquitectura simplista, introduciendo una red con dos capas ocultas que consta de 5 nodos en la primera capa y 3 en la segunda. Este modelo tiene la tarea de predecir el RCC sin la aplicación de la estandarización a las características de entrada.

La introducción de más nodos y una capa oculta adicional permite a este modelo un mayor nivel de abstracción en su proceso de aprendizaje. Se prevé que esta complejidad mejore la capacidad del modelo para capturar relaciones no lineales, lo que podría conducir a una mayor precisión de predicción para RCC. Sin embargo, la falta de estandarización aún podría representar un desafío, especialmente si las características están en diferentes escalas, lo que podría conducir a un proceso de aprendizaje sesgado.




Figura 12-18. Matriz de confusión modelo 5 (conjunto de datos de entrenamiento)

El modelo entrenado en RCC sin estandarización refleja el comportamiento del modelo simple en su sobrepredicción de la clase positiva (merodeador). El modelo arroja un alto número de Verdaderos Positivos (TP = 239), pero lucha con una tasa significativa de Falsos Positivos (FP = 238), lo que indica una falta de especificidad. Los Verdaderos Negativos son bajos (TN = 28), mostrando dificultad para identificar correctamente la clase negativa (viajero). El modelo mantiene un recuento bajo de falsos negativos (FN = 8), lo que significa una buena sensibilidad. Sin embargo, el alto FP indica una necesidad crítica de mejorar la precisión, potencialmente a través de técnicas como el aprendizaje sensible a los costos o la ingeniería de características adicionales para mejorar las capacidades de discriminación del modelo.

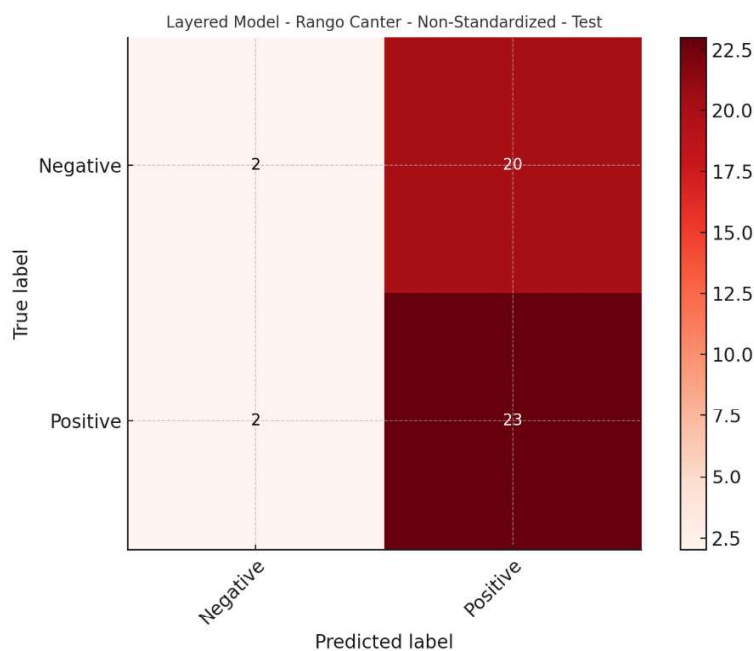


Figura 12-19. Matriz de confusión modelo 5 (conjunto de datos de prueba)

El conjunto de pruebas muestra una tendencia similar, con el modelo mostrando una alta sensibilidad ($TP = 23$) pero poca especificidad ($TN = 2$, $FP = 20$). La tendencia del modelo a predecir la clase positiva conduce a un alto error de Tipo I, lo que refleja los posibles problemas de sobreajuste observados en la fase de entrenamiento. El bajo FN (2) indica que, si bien el modelo captura la mayoría de los casos positivos, su confiabilidad es cuestionable debido al alto número de falsas alarmas. Esto sugiere la necesidad de técnicas de regularización o ajuste de hiperparámetros para mejorar la generalización del modelo.

- Modelo 6 [Red de dos capas] (predicción RCC con estandarización mínimo-máximo)

El modelo 6 conserva la arquitectura del modelo 5, pero introduce la estandarización (min/max) de las funciones antes de introducirlas en la red. Este modelo continúa prediciendo el RCC, ofreciendo una comparación directa del impacto de la estandarización con una estructura de red idéntica.

Al estandarizar las características, el modelo busca mitigar cualquier problema relacionado con las diferentes escalas de características, proporcionando una base más neutral para que la red aprenda. Este proceso podría acelerar el entrenamiento y mejorar la capacidad del modelo para discernir patrones sutiles relacionados con el RCC.




Figura 12-20. Matriz de confusión modelo 6 (conjunto de datos de entrenamiento)

La introducción de la estandarización refuerza significativamente el rendimiento del modelo en capas. Hay una caída dramática en la FP (11) y un aumento sustancial en la TN (255), lo que indica una mejora notable en la especificidad sin sacrificar la sensibilidad (TP = 230). Sin embargo, hay un ligero aumento de la FN (17), lo que sugiere cierta compensación entre la sensibilidad y la especificidad. Este equilibrio es crucial en aplicaciones prácticas, lo que indica que la estandarización ayuda al modelo a generalizar mejor y a hacer predicciones de clase más precisas.

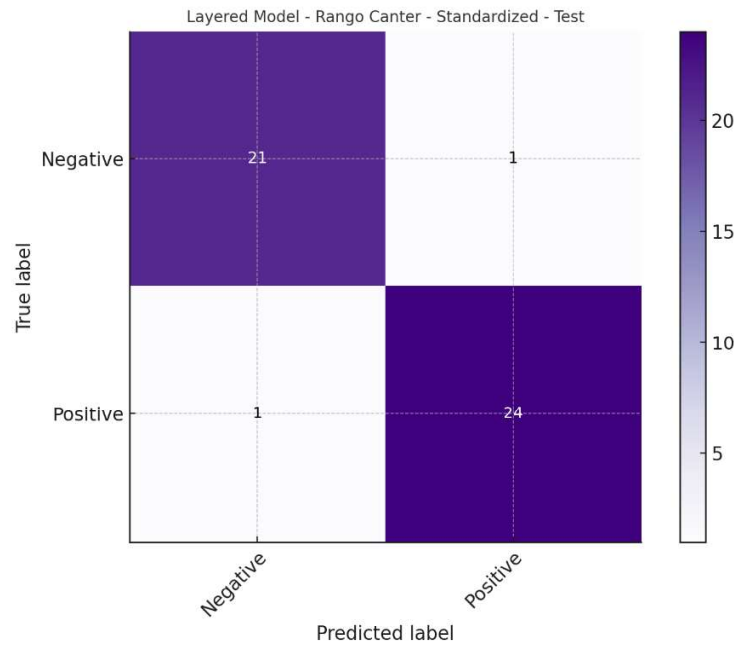


Figura 12-21. Matriz de confusión modelo 6 (conjunto de datos de prueba.)

Las mejoras de rendimiento se trasladan al conjunto de pruebas, ya que el modelo demuestra un excelente equilibrio en las predicciones de clase ($TP = 24$, $TN = 21$) y una reducción significativa en FP (1), lo que muestra una mayor precisión y fiabilidad. El modelo mantiene un FN bajo (1), lo que indica un compromiso mínimo en la sensibilidad. Este rendimiento consistente sugiere que la estandarización de características ayuda significativamente al modelo a aprender un patrón subyacente más generalizable, mejorando así su solidez y precisión predictiva en datos no vistos.

- Modelo 7 [Red de dos capas] (predicción RCH sin estandarización)

El modelo 7 aplica la arquitectura de red de dos capas a la predicción de RCH, sin estandarizar los datos. El rendimiento de este modelo proporciona información sobre la eficacia de una red neuronal más compleja al manejar diferentes variables objetivo y escalas de características.

La complejidad de RCH como objetivo podría abordarse mejor con este modelo debido a su mayor capacidad para aprender relaciones no lineales. Sin embargo, la eficacia de este proceso de aprendizaje podría verse comprometida si las escalas de las características son muy diferentes, lo que subraya la importancia potencial de la estandarización.




Figura 12-22. Matriz de confusión modelo 7(conjunto de datos de entrenamiento)

El desempeño del modelo estratificado en la variable RCH sin estandarización presenta un desafío sustancial en la clasificación de la clase positiva ("merodeador"). El modelo muestra una tasa de Verdaderos Negativos muy alta (TN = 321), lo que indica un fuerte rendimiento en la predicción de la clase "viajero", pero esto tiene un costo significativo para la sensibilidad, con un alto recuento de Falsos Negativos (FN = 171) y una tasa de Verdaderos Positivos muy baja (TP = 15). El bajo Falso Positivo (FP = 6) subraya aún más la postura conservadora del modelo en la predicción de la clase positiva. Este comportamiento podría deberse a un desequilibrio de clase o a características insuficientemente discriminativas para la clase "merodeador", lo que requiere una revisión tanto de la entrada de datos como de la estructura del modelo.

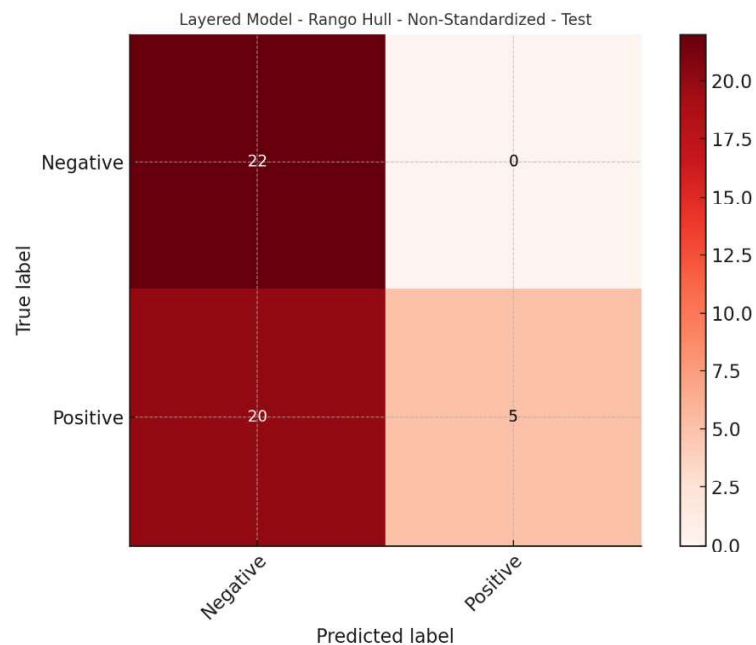


Figura 12-23. Matriz de confusión modelo 8 (conjunto de datos de prueba).

Los datos de las pruebas reflejan los desafíos de la fase de entrenamiento, con una alta especificidad continua (TN = 22) pero una sensibilidad deficiente (TP = 5). El modelo subestima significativamente la clase "merodeador", lo que resulta en un alto número de instancias perdidas (FN = 20) y muy pocos FP (0). Este fuerte error de Tipo II sugiere que el modelo puede ser demasiado rígido debido a un sobreajuste o que tiene problemas con el conjunto de características proporcionado para la variable RCH, lo que requiere una reevaluación de la estrategia para la selección de características, el preprocesamiento de datos o la complejidad del modelo.

- Modelo 8 [Red de dos capas] (predicción RCH con estandarización mínima-máxima)

El modelo final, predice RCH utilizando la misma red de dos capas, pero con la incorporación de la estandarización (min/max). Este ajuste es clave para comprender el impacto total del escalado de características cuando se combina con una arquitectura de red más sofisticada.

Dado que la arquitectura avanzada es potencialmente más adecuada para la complejidad de RCH, la estandarización podría mejorar aún más el rendimiento del modelo al garantizar que el aprendizaje no se vea afectado de manera desproporcionada por ciertas características. Este enfoque equilibrado podría ser crucial para lograr una mayor precisión en las predicciones.




Figura 12-24. Matriz de confusión modelo 8 (conjunto de datos de entrenamiento)

La incorporación de la estandarización mejora drásticamente el rendimiento del modelo, con un aumento sustancial en TP (162) y un excelente TN (324), lo que indica una clasificación más equilibrada. Los FP son extremadamente bajos (3), lo que muestra un aumento significativo en la precisión, y aunque los FN se reducen (24), sugieren que todavía hay margen de mejora en la sensibilidad. El proceso de estandarización parece haber permitido que el modelo comprenda y utilice mejor las características proporcionadas, mejorando su capacidad de aprendizaje y precisión de predicción para la clase positiva.




Figura 12-25. Matriz de confusión modelo 8 (conjunto de datos de prueba).

El conjunto de pruebas muestra mejoras consistentes con la estandarización, mostrando un buen equilibrio entre sensibilidad ($TP = 18$) y especificidad ($TN = 20$). El modelo mantiene una baja tasa de FP (2), lo que indica una alta precisión, y reduce los FN a 7, lo que muestra una mayor robustez del modelo. Estas métricas indican que el modelo, cuando se estandariza, funciona con mayor confiabilidad y generalización, distinguiendo efectivamente entre las clases merodeador y viajero.

Las matrices de confusión para los distintos modelos, tanto simples como estratificados, dirigidas a las variables RCC y RCH, con y sin estandarización, revelan información crítica sobre las características de rendimiento de cada modelo y el impacto de la estandarización en la precisión predictiva.

Una observación consistente en ambos modelos es la mejora significativa en las métricas de rendimiento con la introducción de la estandarización de datos. Para la variable RCC ambos modelos tendieron a sobrepredecir la clase positiva ("merodeador") sin estandarización, lo que llevó a un alto número de falsos positivos. Sin embargo, con la estandarización, hubo un aumento notable de los verdaderos negativos y una disminución de los falsos positivos, lo que mejoró la precisión de los modelos sin comprometer sustancialmente la sensibilidad. Esto indica que la estandarización ayuda a mitigar el sobreajuste del modelo y a mejorar las capacidades de generalización.

Por el contrario, para la variable RCH, los modelos sin estandarización exhibieron un alto grado de conservadurismo, lo que resultó en un número sustancial de Falsos Negativos y una subpredicción de la clase "merodeador". La introducción de la normalización corrigió este desequilibrio en gran medida, lo que dio lugar a un equilibrio más equilibrado entre sensibilidad y especificidad y a una reducción drástica de los errores de tipo II (Falsos Negativos).

En general, el modelo estratificado mostró una mejor respuesta a la estandarización en comparación con el modelo simple, particularmente en su capacidad para mantener o mejorar la sensibilidad al tiempo que mejora significativamente la especificidad. Esto sugiere que los modelos más complejos podrían aprovechar los datos estandarizados de manera más efectiva, posiblemente debido a su capacidad para capturar patrones más matizados en los datos.

Estos hallazgos subrayan el papel crítico del preprocesamiento adecuado de los datos, en particular la estandarización, en el rendimiento de los modelos de redes neuronales. También destacan la importancia de la complejidad del modelo en relación con la naturaleza de los datos, ya que los modelos más complejos requieren un manejo de datos más sofisticado para optimizar

su rendimiento predictivo. Por último, las marcadas diferencias en el rendimiento entre las variables RCC y RCH sugieren que la selección de características y la comprensión del contexto detrás de los datos son cruciales para desarrollar modelos predictivos efectivos.

Métricas de evaluación comparadas

Exactitud (*Accuracy*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y RCC/RCH), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-26: Gráfico de barras de la exactitud del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La precisión del modelo simple muestra un aumento significativo con la estandarización, pasando de aproximadamente 52.05% a 79.34%. Esto sugiere que el modelo se beneficia enormemente de la estandarización de las características, posiblemente porque reduce la influencia de valores atípicos o escalas variables entre las características.

Modelo en capas (Modelo 2): El modelo en capas, por otro lado, demuestra una mejora drástica en la precisión con la estandarización, logrando un impresionante 94.54%. La naturaleza compleja del modelo en capas podría estar capturando patrones más matizados en los datos estandarizados, que no son tan evidentes o están sesgados en los datos no estandarizados.

2. Conjunto de entrenamiento RH

Modelo simple (Modelo 1): Aquí, el modelo simple vuelve a funcionar mejor con la estandarización, pero la diferencia es menos pronunciada que con RCC, con precisiones del 65.11% sin estandarización y del 75.83% con estandarización.

Modelo en capas (Modelo 2): el modelo en capas supera al modelo simple en ambos escenarios, pero muestra un aumento más drástico en el rendimiento con la estandarización, alcanzando una precisión del 94.74 %.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): la precisión del modelo simple aumenta del 53.19 % al 80.85 % con la estandarización, lo que reafirma la importancia del escalado de características en los modelos de redes neuronales.

Modelo en capas (Modelo 2): La estandarización vuelve a ser beneficiosa, ya que el modelo en capas logra una precisión casi perfecta del 95.74 % en comparación con el 53.19 % sin estandarización.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La precisión del modelo simple es mayor sin estandarización (72.34%) en comparación con la estandarización (63.83%). Esto podría deberse a un sobreajuste durante la fase de entrenamiento en el escenario estandarizado, donde el modelo puede haberse adaptado demasiado a los datos de entrenamiento.

Modelo en capas (Modelo 2): A diferencia del modelo simple, el modelo en capas experimenta una mejora con la estandarización, con precisiones del 57.45 % sin estandarización y del 80.85 % con la estandarización.

En casi todos los escenarios, la estandarización parece beneficiar significativamente tanto a los modelos simples como a los estratificados, y el modelo estratificado generalmente supera al modelo simple, probablemente debido a su capacidad para capturar relaciones más complejas en los datos. La única excepción es el modelo simple en el equipo de pruebas RCH, donde la estandarización en realidad disminuye el rendimiento, posiblemente debido al sobreajuste. Esto

pone de relieve la importancia de una validación cuidadosa del modelo y la posible necesidad de técnicas de regularización o estrategias de validación más complejas, como la validación cruzada.

Sensibilidad (*Sensitivity*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras)




Figura 12-27: Gráfico de barras de la sensibilidad del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La sensibilidad mejora drásticamente con la estandarización, de aproximadamente 10.53% a 77.82%. Esto indica que, sin estandarización, el modelo tiene dificultades para identificar correctamente los casos positivos, pero la estandarización mejora significativamente su capacidad para hacerlo.

Modelo en capas (Modelo 2): El modelo en capas funciona excepcionalmente bien con la estandarización, logrando una sensibilidad del 95.86 %, en comparación con el 10.53 % sin estandarización. Esto sugiere que el modelo estratificado puede detectar casi todos los casos positivos cuando los datos están estandarizados.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): Para el RCH, el modelo simple ya tiene una alta sensibilidad sin estandarización (93.27%) y sigue siendo alto con estandarización (92.97%). Esta alta sensibilidad indica una gran capacidad para identificar casos positivos en ambos escenarios.

Modelo en capas (Modelo 2): el modelo en capas logra una sensibilidad casi perfecta con la estandarización (99.08 %), en comparación con el 98.17 % sin estandarización. Ambos valores son extremadamente altos, lo que indica un excelente desempeño en la identificación de casos positivos de RCH.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): La sensibilidad mejora del 9.09% al 77.27% con la estandarización, lo que indica que la capacidad del modelo para identificar correctamente los casos positivos mejora significativamente con la estandarización de los datos.

Modelo por capas (Modelo 2): Con la estandarización, el modelo por capas exhibe una sensibilidad casi perfecta (95.45%) en comparación con el 9.09% sin estandarización, lo que demuestra su robustez en la identificación de casos positivos cuando los datos están estandarizados.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La sensibilidad del modelo simple es muy alta sin estandarización (81.82%) pero aún mayor con estandarización (95.45%). A pesar del cambio en el escalado de los datos, el modelo mantiene una gran capacidad para detectar casos positivos.

Modelo en capas (Modelo 2): el modelo en capas muestra una alta sensibilidad en ambos escenarios, pero es mayor con la estandarización (90.91 %) en comparación con la no estandarización (100 %). La ligera caída sin estandarización podría indicar que el modelo se ajusta demasiado a los datos no estandarizados, lo que hace que funcione ligeramente peor cuando se generaliza a nuevos datos.

Por lo general, la estandarización mejora la sensibilidad tanto en los modelos como en las condiciones, y el modelo en capas suele superar al modelo simple. La capacidad de los modelos para identificar casos positivos (RCC o RCH) aumenta efectivamente con la estandarización, lo

que destaca la importancia del escalado de características en el rendimiento del modelo. Sin embargo, la sensibilidad del modelo en capas disminuye ligeramente sin estandarización en el conjunto de pruebas de Rango Hull, lo que indica un posible sobreajuste a los datos de entrenamiento en ese escenario específico

Especificidad (*Specificity*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-28: Gráfico de barras de la especificidad del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La especificidad es muy alta sin estandarización (96.76%) pero baja al 80.97% con estandarización. Esto sugiere que, si bien el modelo es muy bueno para identificar casos negativos sin estandarización, su rendimiento disminuye cuando se estandarizan los datos. Sin embargo, es importante tener en cuenta que la sensibilidad del modelo fue muy baja sin estandarización, lo que indica un compromiso entre sensibilidad y especificidad.

Modelo estratificado (Modelo 2): Al igual que el modelo simple, el modelo estratificado tiene una especificidad muy alta sin estandarización (96.76%) y experimenta una ligera disminución con la estandarización (93.12%). A pesar de la disminución, la especificidad sigue siendo alta, lo que indica una gran capacidad para identificar correctamente los casos negativos.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): La especificidad es bastante baja sin estandarización (15.59%) pero mejora a 45.70% con estandarización. Esta baja especificidad indica que el modelo tiene dificultades para identificar correctamente los casos negativos, especialmente sin estandarización.

Modelo en capas (Modelo 2): El modelo en capas tiene una especificidad extremadamente baja sin estandarización (8.065%), pero mejora drásticamente al 87.10% con la estandarización. Esto indica que la estandarización mejora significativamente la capacidad del modelo para distinguir entre las dos clases.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): El modelo mantiene una alta especificidad sin estandarización (92.00%) y experimenta una ligera disminución con la estandarización (84.00%). Esto sugiere que el modelo sigue funcionando bien en la identificación de casos negativos en nuevos datos.

Modelo por capas (Modelo 2): El modelo por capas se comporta excepcionalmente bien en ambos escenarios, con un 92.00 % de especificidad sin estandarización y un 96.00 % con estandarización, lo que demuestra una ligera mejora.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La especificidad mejora significativamente del 64.00% sin estandarización al 36.00% con estandarización. Esto sugiere que la estandarización afecta negativamente la capacidad del modelo para identificar casos negativos en el conjunto de pruebas para RCH.

Modelo en capas (Modelo 2): A diferencia del modelo simple, el modelo en capas ve una disminución en la especificidad del 72.00 % sin estandarización al 20.00 % con estandarización. Esta disminución sustancial sugiere que el modelo puede estar sobreajustado a los datos de entrenamiento estandarizados, lo que perjudica su rendimiento en el conjunto de pruebas.

La estandarización parece tener efectos variables sobre la especificidad, dependiendo del modelo y la condición. Si bien generalmente mejora la especificidad para la condición del RCH en el conjunto de entrenamiento, su impacto en el conjunto de prueba es menos consistente. Por lo general, el modelo en capas mantiene una mayor especificidad que el modelo simple. Sin embargo, ambos modelos exhiben un equilibrio entre sensibilidad y especificidad, particularmente el modelo

simple en el equipo de prueba RCH. Esto pone de manifiesto la importancia de tener en cuenta ambas métricas a la hora de evaluar el rendimiento del modelo, ya que la optimización de una puede provocar disminuciones en la otra.

Valor predictivo positivo (*Positive Predictive Value*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-29: Gráfico de barras del valor predictivo del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): El Valor Predictivo Positivo (en adelante VPP) es alto sin estandarización (77.78%) pero aumenta ligeramente con la estandarización hasta el 81.50%. El alto VPP sin estandarización, a pesar de la baja sensibilidad, sugiere que, si bien el modelo identifica los casos positivos de manera conservadora, es preciso cuando lo hace.

Modelo en capas (Modelo 2): El VPP es extremadamente alto con estandarización (93.75%), en comparación con el 77.78% sin estandarización. Esto indica que el modelo no solo es bueno en la detección de casos positivos con estandarización, sino que también es muy confiable en sus clasificaciones positivas.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): El VPP es bastante estable, con un 66.02% sin estandarización y un 75.06% con estandarización. Esta estabilidad sugiere que la fiabilidad del modelo en las predicciones positivas no se ve muy afectada por la estandarización en el caso de RCH.

Modelo estratificado (Modelo 2): El modelo muestra un aumento significativo de la VPP con la estandarización, de 65.24% a 93.10%. Esto sugiere que, si bien las predicciones positivas del modelo son algo confiables sin estandarización, se vuelven significativamente más confiables con la estandarización.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): El VPP es del 50,00% sin estandarización y aumenta al 80.95% con la estandarización. Este aumento significativo indica que la estandarización mejora en gran medida la confiabilidad de las clasificaciones positivas del modelo.

Modelo en capas (Modelo 2): El PPV es perfecto con estandarización (95.45%) y 50,00% sin estandarización. Esta puntuación perfecta indica que cada instancia que el modelo clasifica como positiva es realmente positiva cuando los datos están estandarizados.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): El VPP disminuye de 66.67% sin estandarización a 56.76% con estandarización. Esta disminución sugiere que la estandarización hace que el modelo sea menos confiable en sus predicciones positivas para Rango Hull en el conjunto de pruebas.

Modelo por capas (Modelo 2): El VPP experimenta una disminución del 74.07% sin estandarización al 52.38% con estandarización. Al igual que el modelo simple, esto sugiere que las predicciones positivas del modelo se vuelven menos confiables con la estandarización.

El impacto de la estandarización en el valor predictivo positivo varía según los diferentes escenarios. Si bien generalmente mejora el PPV para la condición de RCC, su efecto en la condición de RCH es menos beneficioso, particularmente en el conjunto de prueba. Esto sugiere que, si bien la estandarización puede mejorar la precisión del modelo, el contexto específico y las características de los datos influyen significativamente en su efectividad. El modelo estratificado generalmente muestra una mayor precisión en comparación con el modelo simple, particularmente con datos estandarizados, lo que indica su confiabilidad superior en la clasificación de casos

positivos. Sin embargo, la disminución del PPV para el equipo de pruebas Rango Hull con estandarización pone de manifiesto posibles sobreajustes o discrepancias en los datos que deben investigarse más a fondo.

Valor predictivo negativo (*Negative Predictive Value*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-30: Gráfico de barras del valor predictivo negativo del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): El valor predictivo negativo (en adelante VAN) es relativamente bajo sin estandarización (50.10%) pero aumenta a 77.22% con estandarización. Esto sugiere que la estandarización mejora significativamente la confiabilidad del modelo en sus clasificaciones negativas.

Modelo estratificado (Modelo 2): El VAN es similar sin estandarización (50.10%) y aumenta ligeramente hasta 95.44% con estandarización. Este alto VAN indica que el modelo es muy confiable en sus clasificaciones negativas cuando los datos están estandarizados.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): El VAN es moderadamente alto sin estandarización (56.86%) y aumenta ligeramente con estandarización (78.70%). Esto indica que la fiabilidad del modelo en las predicciones negativas mejora con la estandarización.

Modelo estratificado (Modelo 2): El VAN es significativamente mayor con estandarización (98.18%) en comparación con sin estandarización (71.43%). Esto sugiere que las predicciones negativas del modelo son extremadamente confiables con la estandarización.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): El VAN es del 53.49% sin estandarización y mejora al 80.77% con la estandarización. Esta mejora sugiere que la estandarización mejora la capacidad del modelo para identificar correctamente los casos negativos.

Modelo estratificado (Modelo 2): El modelo mantiene un alto VAN del 96,00% con estandarización, un aumento significativo en comparación con el 53.49% sin estandarización. Este alto valor indica una excelente confiabilidad en las clasificaciones negativas del modelo con datos estandarizados.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): El VAN es alto sin estandarización (80.00%) pero aún mayor con estandarización (90.00%). Este alto VAN sugiere que el modelo es generalmente confiable en sus clasificaciones negativas, más aún con la estandarización.

Modelo en capas (Modelo 2): El VAN es perfecto (100%) sin estandarización, pero disminuye al 90.00% con la estandarización. La disminución sugiere que, si bien las clasificaciones negativas del modelo siguen siendo muy confiables con la estandarización, lo son algo menos en comparación con el escenario no estandarizado.

La estandarización tiende a mejorar el valor predictivo negativo tanto en los modelos como en las condiciones, particularmente para la condición de RCC. El modelo estratificado suele mostrar un VPN más alto en comparación con el modelo simple, lo que indica su fiabilidad superior en la clasificación de los casos negativos. Sin embargo, el modelo simple también muestra una alta confiabilidad, particularmente con la condición de RCH en el equipo de prueba. La disminución del VAN para el modelo estratificado en el conjunto de pruebas de RCH con estandarización, aunque sigue siendo alta, sugiere matices potenciales en los datos que pueden estar afectando sus predicciones. Esto subraya la importancia de comprender las características de los datos y el contexto en el que se aplica el modelo.

Prevalencia (*Prevalence*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-31: Gráfico de barras de la prevalencia del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelos simples y estratificados: La prevalencia para ambos modelos es la misma, aproximadamente del 51.85%. Esto indica un conjunto de datos casi equilibrado para RCC en el conjunto de entrenamiento, con casi el mismo número de casos positivos y negativos.

2. Conjunto de entrenamiento RCH

Modelos simples y estratificados: La prevalencia vuelve a ser consistente para ambos modelos, con aproximadamente un 63.74%. Esto indica que el conjunto de datos está algo desequilibrado hacia los casos positivos de RCH en el conjunto de entrenamiento, con un mayor número de casos positivos.

3. Conjunto de datos de prueba RCC

Modelos simples y estratificados: La prevalencia se mantiene constante para ambos modelos en el conjunto de prueba, en aproximadamente el 46.81%. Esto sugiere un conjunto de datos casi equilibrado para RCC en el conjunto de pruebas, aunque ligeramente desequilibrado hacia los casos negativos.

4. Conjunto de datos de prueba RCH

Modelos simples y estratificados: La prevalencia para ambos modelos es de alrededor del 46.81%. Esto indica un cambio en comparación con el conjunto de entrenamiento, lo que sugiere que el conjunto de prueba está ligeramente desequilibrado hacia los casos negativos para RCH.

La métrica de prevalencia revela que los conjuntos de datos de RCC están relativamente equilibrados tanto en el conjunto de entrenamiento como en el de prueba, mientras que los

conjuntos de datos de RCH están desequilibrados hacia los casos positivos en el conjunto de entrenamiento y los casos negativos en el conjunto de prueba. Este desequilibrio puede influir en las métricas de rendimiento del modelo, en particular la precisión y la recuperación, y puede requerir estrategias como el remuestreo o el uso de diferentes métricas de rendimiento que se adapten mejor a los conjuntos de datos desequilibrados. También es importante para comprender el contexto en el que se aplican los modelos, ya que los conjuntos de datos del mundo real suelen estar desequilibrados. La coherencia en la prevalencia entre los modelos simple y estratificado indica que se entrenan y prueban en los mismos conjuntos de datos, lo que proporciona una base justa para la comparación

Tasa de detección (*Detection Rate*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y RCC/RCH), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-32: Gráfico de barras de la tasa de detección del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La tasa de detección es significativamente baja sin estandarización (5.46%), pero mejora drásticamente con la estandarización al 40.35%. Esto indica que la estandarización mejora notablemente la capacidad del modelo para identificar correctamente los casos positivos.

Modelo en capas (Modelo 2): Hay un aumento drástico en la tasa de detección con la estandarización, que se eleva al 49.71 % desde un mero 5.46 % sin estandarización. Esto sugiere que el modelo estratificado, cuando se estandariza, detecta casi la mitad de los casos positivos, una mejora sustancial.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): La tasa de detección es alta sin estandarización (59.45%) y se mantiene casi igual con estandarización (59.26%). Esto indica que el modelo es bastante efectivo para identificar casos positivos, con o sin estandarización.

Modelo en capas (Modelo 2): Hay un ligero aumento en la tasa de detección con la estandarización, pasando del 62.57 % al 63.16 %. Ambas tasas son altas, lo que indica la gran capacidad del modelo para detectar casos positivos.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): La tasa de detección es baja sin estandarización (4.26%), pero experimenta un aumento sustancial con la estandarización hasta el 36.17%. Esto sugiere que la estandarización mejora significativamente el desempeño del modelo en la identificación de casos positivos.

Modelo en capas (Modelo 2): La tasa de detección refleja el patrón del modelo simple, con un salto significativo del 4.26 % sin estandarización al 44.68 % con estandarización. Esta mejora subraya el impacto positivo de la estandarización en la capacidad de detección del modelo.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La tasa de detección es moderadamente alta sin estandarización (38.30 %), pero aumenta con la estandarización hasta el 44,68 %. Esto demuestra la mayor competencia del modelo en la detección de casos positivos con datos estandarizados.

Modelo en capas (Modelo 2): hay una disminución en la tasa de detección del 46.81 % sin estandarización al 42,55 % con estandarización. Esta ligera caída sugiere que, para el conjunto de pruebas, la estandarización dificulta ligeramente la capacidad del modelo para detectar casos positivos

La estandarización generalmente mejora la tasa de detección en ambos modelos para RCC, mientras que su impacto en el RCH es menos consistente, particularmente en el conjunto de prueba. El modelo estratificado suele mostrar una tasa de detección más alta en comparación con el modelo simple, lo que indica su capacidad superior para identificar casos positivos. Sin embargo, la disminución en la tasa de detección de RCH en el conjunto de prueba con estandarización para el modelo en capas sugiere un posible sobreajuste a los datos de entrenamiento u otros matices en los datos de prueba que pueden estar afectando sus predicciones. Esto resalta la importancia no solo del escalado de características, sino también de la comprensión de las características del conjunto de datos y los posibles cambios en las distribuciones de datos entre los conjuntos de entrenamiento y de prueba.

Prevalencia de detección (*Detection Prevalence*)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y RCC/RCH), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-33: Gráfico de barras de la prevalencia de la detección del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La prevalencia de detección es baja sin estandarización (7.02%), pero experimenta un aumento significativo con la estandarización hasta el 49.51%. Esto sugiere que la estandarización lleva al modelo a predecir un mayor número de casos como positivos, alineándose más estrechamente con la prevalencia real del 51.85%.

Modelo estratificado (Modelo 2): Con la estandarización, la prevalencia de detección aumenta sustancialmente del 7.02% al 53.02% sin estandarización. El modelo predice que más de la mitad de los casos son positivos con estandarización, ligeramente por encima de la prevalencia real.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): La prevalencia de detección es muy alta sin estandarización (90.06%) y disminuye ligeramente con la estandarización hasta el 78.95%. Sin estandarización, el modelo parece sobrepredecir los casos positivos en comparación con la prevalencia real del 63.74%.

Modelo estratificado (Modelo 2): La prevalencia de detección es extremadamente alta sin estandarización (95.91%) y se ajusta al 67.84% con estandarización. Este ajuste acerca la prevalencia de detección a la prevalencia real, lo que sugiere predicciones más equilibradas.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): La prevalencia de detección es del 8.51% sin estandarización y aumenta notablemente hasta el 44.68% con la estandarización. Este aumento sugiere que la estandarización hace que el modelo clasifique una mayor proporción de casos como positivos.

Modelo estratificado (Modelo 2): La prevalencia de detección aumenta del 8.51% sin estandarización al 46.81% con estandarización, lo que indica que el modelo es más propenso a predecir positivos cuando los datos están estandarizados.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La prevalencia de detección es del 57.45% sin estandarización y aumenta significativamente al 78.72% con estandarización. Esto sugiere que es mucho más probable que el modelo prediga un caso como positivo cuando los datos están estandarizados.

Modelo estratificado (Modelo 2): Hay un aumento en la prevalencia de detección del 89.36% sin estandarización al 57.45% con estandarización. Esta disminución con la estandarización indica que el modelo está menos inclinado a predecir aspectos positivos, posiblemente intentando corregir la sobrepredicción observada sin estandarización.

La estandarización generalmente aumenta la prevalencia de detección tanto en modelos como en condiciones, con la excepción del modelo en capas para RCH en el conjunto de pruebas. Los modelos, especialmente el modelo simple, tienden a sobrepredicir los aspectos positivos para RCH sin estandarización, lo que la estandarización ayuda a corregir. Esta sobrepredicción podría conducir a una mayor tasa de falsos positivos, lo que demuestra la importancia de considerar la prevalencia de detección junto con otras métricas como el valor predictivo positivo. El modelo en capas suele mostrar una mayor prevalencia de detección en comparación con el modelo simple, aunque se ajusta más con la estandarización, lo que sugiere una respuesta más matizada al escalado de características.

Precisión Equilibrada (Balanced Accuracy)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo

simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-34: Gráfico de barras de la precisión equilibrada del rendimiento de dos modelos comparados

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): La precisión equilibrada es moderada sin estandarización (53.64 %), pero mejora considerablemente con la estandarización hasta el 79.40 %. Esta mejora indica que la estandarización mejora significativamente el rendimiento general de la clasificación del modelo para ambas clases.

Modelo en capas (Modelo 2): El modelo muestra un aumento sustancial en la precisión equilibrada con la estandarización, saltando del 53.64% al 94.49%. Esto sugiere que el modelo estratificado logra un excelente equilibrio de clases en sus predicciones con datos estandarizados.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): La precisión equilibrada es bastante baja sin estandarización (54.43%), pero experimenta un aumento notable con la estandarización hasta el 69.33%. Esto indica que, si bien el modelo se esfuerza por equilibrar la sensibilidad y la especificidad sin estandarización, su rendimiento mejora significativamente con él.

Modelo en capas (Modelo 2): Hay un aumento significativo en la precisión equilibrada con la estandarización, del 53.12 % al 93.09 %. Esto sugiere que la estandarización ayuda en gran medida al modelo a lograr una clasificación más equilibrada de ambas clases.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): La precisión equilibrada es del 50.55 % sin estandarización y aumenta sustancialmente al 80.64 % con la estandarización. Esta mejora refleja el impacto positivo de la estandarización en la capacidad del modelo para clasificar correctamente tanto los casos positivos como los negativos.

Modelo en capas (Modelo 2): la precisión equilibrada aumenta del 50.55 % sin estandarización al 95.73 % con estandarización, lo que indica un equilibrio de clases casi perfecto en las predicciones del modelo cuando se estandarizan los datos.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): La precisión equilibrada es decente sin estandarización (72.91 %), pero disminuye con la estandarización al 65.73 %. Esta disminución sugiere que la estandarización, en este caso, dificulta la capacidad del modelo para lograr un buen equilibrio entre sensibilidad y especificidad.

Modelo en capas (Modelo 2): hay una disminución en la precisión equilibrada del 60.00 % sin estandarización al 81.45 % con estandarización. A pesar de la disminución, la precisión equilibrada con la estandarización sigue siendo relativamente alta, lo que indica un fuerte equilibrio en las predicciones de clase.

La estandarización generalmente mejora la precisión equilibrada en ambos modelos y condiciones, particularmente para la condición de RCC. El modelo en capas suele superar al modelo simple, especialmente con datos estandarizados, lo que sugiere que su complejidad puede permitirle capitalizar mejor los beneficios de la estandarización. Sin embargo, la disminución de la precisión equilibrada para el conjunto de pruebas RCH con la estandarización, particularmente para el modelo simple, indica un posible sobreajuste u otras complejidades en los datos que están afectando negativamente el rendimiento. Esto resalta la importancia de tener en cuenta la precisión equilibrada, especialmente en conjuntos de datos desequilibrados, para obtener una imagen más clara del rendimiento real de un modelo en todas las clases.

Kappa (Cohen's Kappa)

Cada celda de la cuadrícula de 2×2 corresponde a una combinación de condiciones (*Train/Test* y *RCC/RCH*), y dentro de cada celda, este informe compara el rendimiento del modelo simple (Modelo 1) y el modelo en capas (Modelo 2) bajo estandarización y sin estandarización (representado por diferentes colores en las barras).




Figura 12-35: Gráfico de barras de Cohen's Kappa del rendimiento de dos modelos comparados.

1. Conjunto de entrenamiento RCC

Modelo simple (Modelo 1): El valor de Kappa es bajo sin estandarización (0.0705), pero experimenta un aumento significativo con la estandarización a 0.5869. Esto sugiere que la

estandarización mejora notablemente el rendimiento predictivo del modelo más allá de lo que se esperaría solo por casualidad.

Modelo en capas (Modelo 2): Hay un aumento drástico en el valor de Kappa con la estandarización, de 0.0705 a 0.8906. Este alto valor de Kappa indica un excelente nivel de concordancia entre las predicciones del modelo y los valores reales cuando se estandarizan los datos.

2. Conjunto de entrenamiento RCH

Modelo simple (Modelo 1): El valor de Kappa es bastante bajo sin estandarización (0.1051), pero experimenta un aumento sustancial con la estandarización a 0.4251. Esto indica que las predicciones del modelo se alinean más estrechamente con los valores reales cuando se estandarizan los datos, aunque todavía hay un margen de mejora considerable.

Modelo en capas (Modelo 2): Hay un aumento significativo en el valor de Kappa con la estandarización, de 0.077 a 0.8833. Esto sugiere que la estandarización mejora en gran medida la capacidad del modelo para hacer predicciones que concuerden con las etiquetas reales.

3. Conjunto de datos de prueba RCC

Modelo simple (Modelo 1): El valor de Kappa es extremadamente bajo sin estandarización (0.0115) pero aumenta notablemente a 0.6144 con estandarización. Esto indica que, si bien las predicciones del modelo se producen en gran medida por casualidad sin estandarización, su rendimiento predictivo mejora significativamente con la estandarización.

Modelo en capas (Modelo 2): el valor de Kappa aumenta de 0.0115 sin estandarización a 0.9145 con estandarización, lo que indica un nivel excepcionalmente alto de concordancia entre las predicciones del modelo y los valores reales cuando se estandarizan los datos.

4. Conjunto de datos de prueba RCH

Modelo simple (Modelo 1): el valor de Kappa es moderado sin estandarización (0.452) pero disminuye con la estandarización a 0.3022. Esto sugiere que la estandarización, en este caso, disminuye el rendimiento predictivo del modelo más allá del azar.

Modelo en capas (Modelo 2): hay una disminución en el valor de Kappa de 0.1897 sin estandarización a 0.6206 con estandarización. A pesar de la disminución, el valor de Kappa con estandarización indica un buen nivel de acuerdo más allá del azar.

La estandarización generalmente mejora el estadístico Kappa tanto en los modelos como en las condiciones, particularmente para la condición de RCC. El modelo en capas generalmente logra un valor Kappa más alto en comparación con el modelo simple, especialmente con datos estandarizados, lo que sugiere que sus predicciones suelen estar de acuerdo con los valores reales. La disminución de Kappa para el conjunto de pruebas de RCH con estandarización, particularmente para el modelo simple, indica problemas potenciales como el sobreajuste u otras idiosincrasias específicas del conjunto de datos que afectan negativamente el rendimiento. La sensibilidad de la estadística Kappa al equilibrio de clases y errores de predicción la convierte en una métrica valiosa para comprender el rendimiento de un modelo más allá de la simple precisión, especialmente en conjuntos de datos con clases desequilibradas o alta complejidad.

Al analizar las métricas de rendimiento en dos modelos de redes neuronales, un modelo simple de un solo nodo y un modelo más complejo de dos capas, surgen varias ideas clave sobre el impacto de la estandarización y la complejidad del modelo en el rendimiento predictivo.

La estandarización generalmente mejora el rendimiento del modelo, sobre todo en el modelo en capas en casi todas las métricas, lo que sugiere que el modelo más complejo se beneficia más de la estandarización, posiblemente debido a su capacidad para capitalizar las relaciones más matizadas en los datos estandarizados. Esta mejora es más pronunciada en métricas como la precisión, la sensibilidad, el valor predictivo positivo (VPP) y el Kappa, donde la estandarización parece corregir las tendencias de los modelos a predecir en exceso o en defecto los casos positivos, alineando así las predicciones más estrechamente con los valores reales.

Sin embargo, la influencia de la estandarización es menos consistente para la condición del casco de rango, particularmente en el conjunto de prueba, donde a veces observamos una disminución del rendimiento con la estandarización, como se ve en métricas como Precisión equilibrada y Kappa para el modelo simple. Esto sugiere un posible sobreajuste en el modelo más complejo o tal vez que la condición de RCH presenta una tarea de predicción más desafiante que no se aborda suficientemente solo con la estandarización.

La prevalencia, una característica del conjunto de datos en lugar de una métrica de rendimiento del modelo, revela un contexto interesante, que indica desequilibrios en el conjunto de datos con los que deben lidiar los modelos. Es probable que estos desequilibrios contribuyan a que los modelos varíen en el rendimiento de las condiciones y las métricas.

El modelo en capas generalmente supera al modelo simple, especialmente cuando los datos están estandarizados, lo que indica los beneficios de una mayor complejidad del modelo en la

captura de relaciones más complejas en los datos. Sin embargo, la respuesta matizada de las diferentes métricas a la estandarización subraya la importancia de una estrategia de evaluación integral a la hora de evaluar el rendimiento del modelo, especialmente en contextos con clases desequilibradas o relaciones complejas y multifacéticas.

Resultados Caso Instrumental / Fuera de muestra

La clasificación de SHOs entre merodeador y viajero se basa en la geografía de sus actos delictivos. Esta distinción, influenciada por la distancia entre delitos, refleja más su patrón de movimiento que una característica intrínseca.

Sin embargo, un desafío es la posibilidad de clasificaciones mixtas: un delincuente podría ser etiquetado como viajero en una serie de delitos y como merodeador en la siguiente.

En la figura 12-48 y 12-49 se puede observar la variación del rango criminal en cada serie y las posibilidades de que el punto de anclaje pueda quedar fuera de la tipología de merodeador o viajero, y en la tabla 12-8 se puede examinar el valor real y el predicho de los dos modelos RCC/RCH y la tipología de delincuente merodeador o viajero, durante las 20 series del caso instrumental de Peter Sutcliffe.

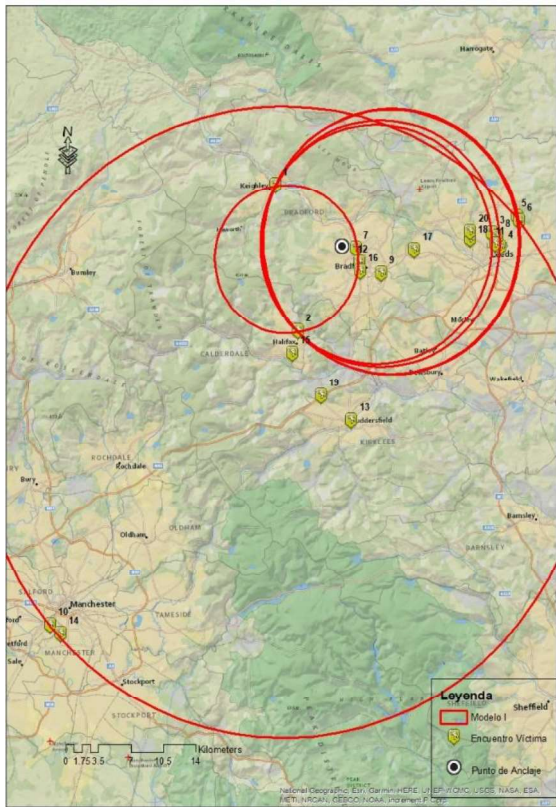


Figura 12-36: Caso Instrumental [Modelo RCC]

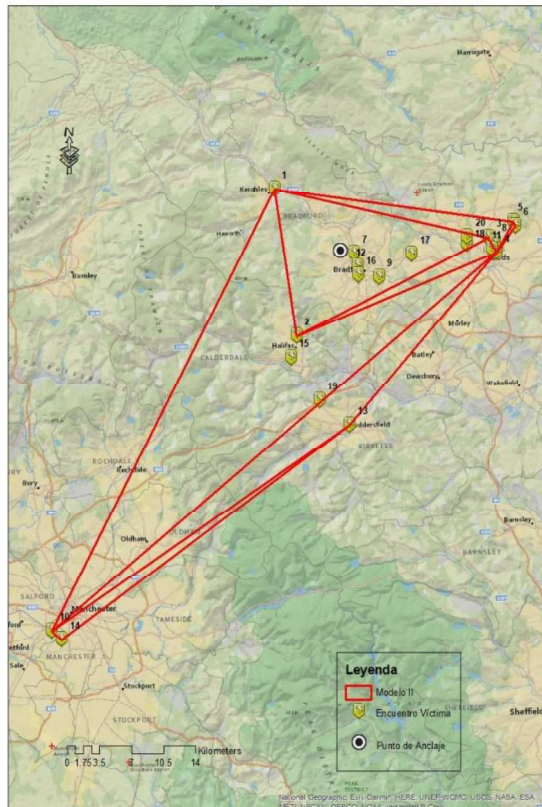


Figura 12-37: Caso Instrumental [Modelo RCH]

Tabla 12-8

Test de los datos de Peter Sutcliffe en los modelos RCC y RCH

Serie	Modelo I (RCC)		Modelo II (RCH)	
	Valor Real	Predicción	Valor Real	Predicción
Caso Instrumental				
2	0	0	1	0
3	1	0	1	1
4	1	1	1	1
5	1	1	1	1
6	1	1	1	1
7	1	1	1	1
8	1	1	1	1
9	1	1	1	1
10	1	1	1	1
11	1	1	1	1
12	1	1	1	1
13	1	1	1	1
14	1	1	1	1
15	1	1	1	1
16	1	1	1	1
17	1	1	1	1
18	1	1	1	1
19	1	1	1	1
20	1	1	1	1

Merodeador (1) Viajero (0)

- Rendimiento fuera de muestra

Para una evaluación realista de los modelos RCC y RCH, es esencial analizarlos utilizando un conjunto de datos de prueba que no se haya empleado ni en el entrenamiento ni en la validación. Estos datos ofrecen una comprobación fidedigna de cómo un algoritmo de aprendizaje automático se comporta ante información no previamente vista, garantizando que su entrenamiento fue efectivo.

Al representar datos que el modelo no ha procesado anteriormente, el conjunto de prueba es crucial para medir la habilidad del modelo de gestionar información nueva. Evaluar su rendimiento en este conjunto brinda una perspectiva objetiva sobre su utilidad en situaciones reales. Esta evaluación determina si el modelo ha capturado adecuadamente los patrones relevantes y si puede realizar predicciones precisas fuera de los escenarios de entrenamiento y validación.

La razón por la que hacemos esto es que, en el modelado predictivo (GEO-SCRIPT), lo que más nos interesa es un modelo que haga predicciones hábiles.

Esto podría significar que elegimos un modelo que parece haberse sobreajustado al conjunto de datos de entrenamiento. En cuyo caso, un análisis de sobreajuste podría ser engañoso.

También podría significar que el modelo tiene un rendimiento deficiente en el conjunto de datos de entrenamiento.

El conjunto de datos de prueba utilizados son 7 SHOs y 47 series, que corresponden a 20 series con tipología de viajero (0) y 27 merodeador (1), véase tabla 12-9.

El resultado obtenido utilizando la herramienta GEO-SCRIPT es de un 91,5% de efectividad.

Tabla 12-9*Conjunto de datos de prueba.*

SHOs	Identificación	Valores reales	Valores predichos
Denis Rader	2017025-205135-2	0	0
Denis Rader	2017025-205135-3	0	0
Denis Rader	2017025-205135-4	0	0
Denis Rader	2017025-205135-5	0	0
Denis Rader	2017025-205135-6	0	0
Denis Rader	2017025-205135-7	0	0
Pietro PACCIANI	20170424-194503-2	0	0
Pietro PACCIANI	20170424-194503-3	0	0
Pietro PACCIANI	20170424-194503-4	0	0
Pietro PACCIANI	20170424-194503-5	0	1
Mauricio MINGUELLA	20170923-183343-2	0	0
Mauricio MINGUELLA	20170923-183343-3	0	1
Mauricio MINGUELLA	20170923-183343-4	1	1
Mauricio MINGUELLA	20170923-183343-5	1	1
Cristhopher WORNELL	20171031-112018-2	0	0
Cristhopher WORNELL	20171031-112018-3	1	1
Cristhopher WORNELL	20171031-112018-4	1	1
Cristhopher WORNELL	20171031-112018-5	1	1
Cristhopher WORNELL	20171031-112018-6	1	1
Cristhopher WORNELL	20171031-112018-7	1	1
Lazarus NAZINGONE	20171113-222527-1	1	0
Lazarus NAZINGONE	20171113-222527-1	0	0
Lazarus NAZINGONE	20171113-222527-1	1	1
Lazarus NAZINGONE	20171113-222527-3	1	1
Lazarus NAZINGONE	20171113-222527-5	1	1
Lazarus NAZINGONE	20171113-222527-6	1	1
Lazarus NAZINGONE	20171113-222527-8	1	1
Lazarus NAZINGONE	20171113-222527-9	1	1
Lazarus NAZINGONE	20171113-222527-91	1	1
Lazarus NAZINGONE	20171113-222527-92	1	1
Lazarus NAZINGONE	20171113-222527-93	1	1
Lazarus NAZINGONE	20171113-222527-94	1	1

SHOs	Identificación	Valores reales	Valores predichos
Lazarus NAZINGONE	20171113-222527-95	1	1
Lazarus NAZINGONE	20171113-222527-96	1	1
Lazarus NAZINGONE	20171113-222527-97	1	1
Wolfong SCHMIDT	20171114-171055-2	0	0
Wolfong SCHMIDT	20171114-171055-3	0	0
Wolfong SCHMIDT	20171114-171055-4	0	0
Wolfong SCHMIDT	20171114-171055-5	0	0
Zdsislaw MARCHIUCKI	20181023-273230-2	0	0
Zdsislaw MARCHIUCKI	20181023-273230-3	0	0
Zdsislaw MARCHIUCKI	20181023-273230-4	1	0
Zdsislaw MARCHIUCKI	20181023-273230-5	0	0
Zdsislaw MARCHIUCKI	20181023-273230-6	0	0
Zdsislaw MARCHIUCKI	20181023-273230-7	1	1
Zdsislaw MARCHIUCKI	20181023-273230-8	1	1
Zdsislaw MARCHIUCKI	20181023-273230-9	1	1

Merodeador (1) Viajero (0)

Prediction:

Marauder (1)

Predicted	Actual	Freq
0	0	22
1	0	0
0	1	3
1	1	22

```

Confusion Matrix and Statistics

          Reference
Prediction 0 1
0 22 3
1 0 22

          Accuracy : 0.9362
          95% CI : (0.8246, 0.9866)
    No Information Rate : 0.5319
    P-Value [Acc > NIR] : 1.553e-09

          Kappa : 0.8729

    McNemar's Test P-Value : 0.2482

          Sensitivity : 1.0000
          Specificity : 0.8800
    Pos Pred Value : 0.8800
    Neg Pred Value : 1.0000
          Prevalence : 0.4681
          Detection Rate : 0.4681
    Detection Prevalence : 0.5319
    Balanced Accuracy : 0.9400

    'Positive' Class : 0
  
```

Figura 12-38: Resultado MARCHIUCKI 20181023.273230-8 (1) merodeador

Prediction:

Commuter (0)

Predicted	Actual	Freq
0	0	22
1	0	0
0	1	3
1	1	22

```

Confusion Matrix and Statistics

          Reference
Prediction 0 1
0 22 3
1 0 22

          Accuracy : 0.9362
          95% CI : (0.8246, 0.9866)
    No Information Rate : 0.5319
    P-Value [Acc > NIR] : 1.553e-09

          Kappa : 0.8729

    McNemar's Test P-Value : 0.2482

          Sensitivity : 1.0000
          Specificity : 0.8800
    Pos Pred Value : 0.8800
    Neg Pred Value : 1.0000
          Prevalence : 0.4681
          Detection Rate : 0.4681
    Detection Prevalence : 0.5319
    Balanced Accuracy : 0.9400

    'Positive' Class : 0
  
```

Figura 12-39: Resultado MARCHIUCKI 20181023.273230-6 (0) viajero

Conclusiones

La elaboración de perfiles geográficos de delincuentes puede ser valiosa para las investigaciones siempre y cuando se cumplan ciertos supuestos relacionados con el patrón de las escenas del delito. La efectividad de estos métodos depende de que el delincuente resida dentro del patrón espacial de sus delitos.

Este capítulo se centra en la clasificación del patrón espacial de los lugares de delitos a través de dos modelos de aprendizaje automático supervisado. Se examinan en términos de su capacidad para reflejar un comportamiento delictivo, los modelos de Canter y Larkin (1993) y el modelo de Warren, basado en la residencia conocida del delincuente. Se destaca la dificultad en la predicción precisa de quién cometerá un asesinato en el futuro, sugiriendo que tales predicciones pueden ser más apropiadas en el ámbito de la ciencia ficción. No obstante, se reconoce la importancia de los intentos realistas de perfilar secuencias de comportamientos y eventos que puedan indicar ciertos tipos de SHO, los cuales son posibles y extremadamente relevantes para la investigación criminal en el marco del perfilado geográfico.

Al intentar discernir entre perfiles delictivos, como el de un merodeador o un viajero, se ha optado en gran medida por los modelos de regresión logística. Esta elección se debe, en parte, a que la estructuración y documentación de estos modelos tiendan a ser más exhaustivas que en las redes neuronales artificiales. Muchos softwares comerciales dedicados a la regresión logística incorporan de manera intuitiva técnicas de selección de variables, facilitando así su uso e informe. En contraposición, trabajar de manera detallada con redes neuronales suele requerir un

compromiso y experiencia más profunda por parte del analista, dado que no siempre se encuentran herramientas avanzadas de manera inmediata en los programas estándar.

A pesar de esto, basado en la investigación realizada hasta el momento, es ampliamente reconocido que todavía no se ha encontrado ningún algoritmo que satisfaga todos los requisitos y necesidades para clasificar el comportamiento de desplazamiento de un SHO. Por lo tanto, en este capítulo, se ha comparado algunos de los algoritmos de aprendizaje automático en el contexto de modelar aquellas variables que se obtienen antes de ser detenido el SHO. Según la evaluación del rendimiento de los algoritmos seleccionados para esta investigación (red neuronal y regresión logística), los resultados de los modelos presentados en la tabla 12-10, se destaca que la precisión obtenida para la red neuronal y la regresión logística se encuentra en rangos aceptables. La sensibilidad promedio de la red neuronal backpropagation es significativamente superior a la de la regresión logística, lo que sugiere que la red neuronal tiene un mejor desempeño en la detección. En contraste, la especificidad de ambos modelos muestra una mayor similitud, indicando que ambos modelos determinan de manera aceptable los casos negativos.

Tabla 12-10*Cuadro Resumen*

	Precisión	Sensibilidad	Especificidad
RCC (RL)	75.49%	76.00%	75.00%
RCH (RL)	69.32%	87.88%	41.67%
RCC (ANN Train) SM	79.34%	77.82%	80.97%
RCC (ANN Train) LM	94.54%	95.86%	93.12%
RCH (ANN Train) SM	75.83%	92.97%	45.70%
RCH (ANN Train) LM	94.74%	99.08%	87.10%
RCC (ANN Test) SM	80.85%	77.27%	84.00%
RCC (ANN Test) LM	95.74%	95.45%	92.00%
RCH (ANN Test) SM	63.83%	95.45%	36.00%
RCH (ANN Test) LM	80.85%	100%	20.00%

RCC [Range Criminal Circle] RCH [Range Convex Hull Polygon]

RL [Regresión Logística] ANN[Red Neuronal]

SM [Capa oculta única] LM [Dos capas ocultas]

En la primera parte del estudio, se destacó la regresión logística como una valiosa herramienta analítica para examinar resultados dicotómicos (merodeador o viajero). Su eficacia quedó respaldada mediante diversas pruebas y métricas.

Utilizando variables geográficas, se logró predecir con un 75.4% de precisión las series delictivas de SHO en el modelo de [Hipótesis Círculo] y un 69.3% en el modelo de la [Envolvente Convexa], obteniendo buena capacidad predictiva al tener valores altos tanto de sensibilidad como

de especificidad, por el contrario, el modelo II [Envolvente Convexa], obtiene valores bajos en la especificidad.

En conclusión, se han identificado variables clave en dos modelos de perfilación geográfica: el Modelo I (Hipótesis Círculo) y el Modelo II (Envolvente Convexa). En el Modelo I, las variables relacionadas con el índice del vecino más cercano, el área del círculo basada en los dos crímenes más lejanos y la distancia entre los dos puntos más alejados influyen fuertemente en la predicción de si un sospechoso es un merodeador o un viajero. Estas variables contrastan con estudios anteriores Kocsis y Irwin (1997) y resaltan la importancia de la concentración y la distancia en la serie de delitos y con Paulsen (2006) donde dos variables espaciales, el área del polígono convexo que delimita las zonas de delito y el índice del vecino más cercano (NNI), influyen notablemente en la previsibilidad. De todas las variables, el NNI es la más determinante para las predicciones, sugiriendo que la concentración de los lugares de delito es crucial para anticipar la naturaleza del delincuente.

En el Modelo II, variables como la distancia media entre el centroide y el incidente delictivo, la distancia media y mínima entre cada delito de la serie, y la distancia entre los dos puntos más alejados, contribuyen significativamente a la predicción. Estos hallazgos contrastan con otras investigaciones Laukkanen (2007) y Lundrigan y Czarnomski (2006), subrayando la complejidad y la variabilidad en la identificación de merodeadores y viajeros.

En la segunda parte del estudio, se destacó las redes neuronales como una valiosa herramienta analítica para examinar resultados dicotómicos (merodeador o viajero). Su eficacia se respaldó mediante diversas pruebas y métricas, que abarca tanto matrices de confusión como

extensas métricas de rendimiento, el impacto transformador de la estandarización, la interacción matizada entre la complejidad del modelo y las características de los datos.

Un tema constante es una mejora pronunciada en el rendimiento del modelo tras la aplicación de la estandarización de datos, un paso de preprocesamiento que recalibra las escalas de características, fundamental para los algoritmos sensibles a la magnitud de entrada. Para la variable RCC equivalente al modelo I de [Hipótesis Círculo], la estandarización redujo significativamente la propensión de ambos modelos a sobrepredecir la clase "merodeador", como lo demuestra el aumento de los Verdaderos Negativos y la bajada de los Falsos Positivos. Este ajuste no solo reforzó la precisión, sino que también preservó la sensibilidad, lo que sugiere el papel de la estandarización en la moderación del sobreajuste y la amplificación de la generalización del modelo.

Por el contrario, los modelos entrenados en la variable RCH equivalente al modelo II [Envolverte Convexa], sin estandarización fueron marcadamente conservadores, prediciendo menos de "merodeadores" y acumulando un exceso de Falsos Negativos. La estandarización corrigió este sesgo, equilibrando la dinámica sensibilidad-especificidad y reduciendo drásticamente los errores de Tipo II, lo que indica su necesidad de una predicción equilibrada de la clase.

El modelo en capas, con su intrincada arquitectura, demostró una adaptabilidad superior a la estandarización en comparación con su contraparte más simple. Su capacidad para mantener o aumentar la sensibilidad, al tiempo que eleva notablemente la especificidad, subraya la premisa de que los modelos complejos, con su elaborada capacidad de representación, pueden aprovechar más hábilmente los patrones matizados revelados por la estandarización.

Las métricas de rendimiento, que se extienden más allá de la precisión tradicional para incluir Kappa, precisión equilibrada y tasas de detección, proporcionaron una visión multifacética del rendimiento del modelo. Estas métricas, especialmente cuando se yuxtaponen con las matrices de confusión, destacaron las variadas eficiencias de los modelos en la predicción de clases, la propensión al error y la concordancia con valores reales más allá del azar. El modelo en capas generalmente eclipsó el modelo simple en estas métricas, particularmente con datos estandarizados, afirmando los beneficios de la complejidad en las redes neuronales. Sin embargo, esta superioridad fue cuestionada en ocasiones, especialmente en la condición de RCH en el conjunto de pruebas con estandarización, lo que sugiere un posible sobreajuste o complejidades específicas de los datos (La variación del ámbito delictivo que utiliza el RCH, a diferencia del RCC, genera una zona de trabajo del delincuente más reducido. Esto la hace más rigurosa para determinar si un delincuente reside dentro o fuera de esta zona. Al ser el área definida por la envolvente convexa notablemente más pequeña que la del modelo de círculo, permite una delimitación más precisa del área de búsqueda inicial).

La marcada dicotomía de rendimiento entre las variables de RCC y RCH acentúa la importancia de la selección de características y la comprensión contextual de los datos en la creación de modelos predictivos sólidos.

Por el contrario, los modelos entrenados en RCH sin estandarización eran marcadamente conservadores, con frecuencia con tendencia a subpredecir a los "merodeadores" y acumulaban un exceso de Falsos Negativos. Esta postura conservadora dio lugar a un número sustancial de clasificaciones positivas perdidas, lo que comprometió la sensibilidad de los modelos. Sin embargo, la introducción de la estandarización corrigió este sesgo, equilibrando la dinámica

sensibilidad-especificidad. Este cambio condujo a un enfoque más equilibrado en las predicciones de clase, reduciendo efectivamente los errores de Tipo II y mejorando la capacidad de los modelos para identificar correctamente los casos positivos, lo que indica el papel crítico de la estandarización en el logro de una predicción de clase equilibrada y precisa.

Además, el modelo en capas, con su arquitectura más compleja, demostró consistentemente una adaptabilidad y un rendimiento superiores en respuesta a la estandarización en comparación con su contraparte más simple. Esta superioridad fue más evidente en su capacidad para mantener o incluso mejorar la sensibilidad, al tiempo que mejoraba significativamente la especificidad, lo que indica una comprensión y representación más matizada de los datos. Esto sugiere que los modelos más complejos, con sus arquitecturas más profundas e intrincadas, pueden aprovechar de manera más efectiva los beneficios que ofrece la estandarización, probablemente debido a su mayor capacidad para capturar y representar patrones y relaciones más sutiles dentro de los datos.

En relación con la Hipótesis 4 de la tesis doctoral, se obtuvo una respuesta afirmativa. Las características espaciales de una serie de incidentes de incidentes delictivos nos permitieron predecir si un SHO es merodeador o viajero con una efectividad en la clasificación utilizando un modelo de regresión logística en un 75.4% en RCC y un 71.5% en RCH y utilizando un modelo de redes neuronales en un 95.7% en RCC y un 80.8% en RCH.

Estos hallazgos subrayan colectivamente el papel indispensable del preprocesamiento adecuado de datos, en particular la estandarización, para mejorar el rendimiento de los modelos de redes neuronales. También destacan la interacción matizada entre la complejidad del modelo y el preprocesamiento de datos, lo que sugiere que, si bien los modelos más complejos pueden ofrecer un rendimiento mejorado, también requieren un manejo de datos más cuidadoso y sofisticado para

aprovechar plenamente su potencial. Además, las diferencias pronunciadas en el rendimiento del modelo entre las variables RCC y RCH subrayan la importancia de la selección matizada de características y una comprensión profunda y contextual de los datos que se utilizan. Esto es crucial para desarrollar modelos predictivos eficaces y robustos que funcionen bien en varios escenarios y conjuntos de datos.

En conclusión, cada enfoque se asocia con sus propias cualidades únicas, seleccionar el modelado más apropiado dependerá por completo de las características del entorno en el que se cometió un delito, lo que generalmente requiere un enfoque de prueba y error (Levine, 2002). Es muy probable que los modelos óptimos utilizados para predecir el punto de anclaje de un delincuente varíen en función del tipo de delito.

Determinar cuándo y cómo usar redes neuronales es esencial, especialmente con la existencia de otros métodos analíticos.

Capítulo 13

FUNCIONES DECAIMIENTO DE LA DISTANCIA

Resumen

Numerosos estudios han demostrado que la distancia que los delincuentes recorren para cometer un delito suele seguir un patrón de decaimiento. Sin embargo, hay una investigación empírica limitada que determina cuál es el modelo matemático más adecuado para describir este comportamiento. En una era donde las técnicas de perfilación geográfica, que se basan en estos patrones de decaimiento, están cobrando mayor importancia, es vital determinar qué modelo matemático refleja de manera más fidedigna los patrones de desplazamiento delictivo. Además, es esencial entender cómo la selección de dicho modelo puede influir en la efectividad del sistema de perfilación geográfica. Las funciones de decaimiento de la distancia, conocidas como “*distance decay*”, parecen una simplificación excesiva de las relaciones complejas entre muchos predictores que desempeñan un papel en los resultados del perfil geográfico. Es necesario avanzar más allá del modelo actual, ya que podría ofrecer pistas importantes sobre las motivaciones y el razonamiento del delincuente en su camino hacia el lugar del delito. Un modelo tridimensional que integra a) los procesos cognitivos del delincuente, b) el esfuerzo requerido durante su desplazamiento, y c) las oportunidades y el atractivo del objetivo, sería esencial para comprender de manera integral el desplazamiento de los delincuentes hacia la comisión del delito.

Introducción

En este capítulo, se profundiza en el tercer tipo de estrategias de perfil geográfico (estrategias de probabilidad de distancia), como se describe en el capítulo 4, y su implementación mediante modelos matemáticos para describir las funciones de disminución de la distancia, que desempeñan un papel crucial en la elaboración de perfiles geográficos. Los programas de software diseñados para la creación de perfiles geográficos se fundamentan en estos modelos.

En este contexto, el presente capítulo destaca la relevancia de la Primera Ley en Geografía, la cual ha contribuido significativamente tanto a los aspectos teóricos como prácticos de la disciplina geográfica. La primera ley de Tobler (1970, p.236) de las condiciones de la geografía dice que "todo está relacionado con todo lo demás, pero las cosas cercanas están más relacionadas que las distantes", y puede aplicarse a una variedad de conceptos geográficos diferentes, en referencia al efecto disuasivo que representa el aumento de la distancia con respecto a las interacciones.

La trascendencia de este planteamiento es difícil de apreciar sin primero entender el impacto de la revolución cuantitativa en la Geografía. Esta transformación tuvo su foco principal en Estados Unidos durante la mitad del siglo XX. Esta metamorfosis introdujo un novedoso paradigma, que Haggett (1994) describe como una especie de supermodelo, estableciendo directrices tanto intuitivas como inductivas sobre qué fenómenos deben ser el objeto de estudio de los científicos. Aunque han pasado décadas y hemos sido testigos de la evolución y perfeccionamiento tecnológico, numerosos principios de la "Nueva Geografía" se mantienen vigentes, en gran medida, debido al constante uso y avance SIG (Celemin, 2020).

Este pensamiento encapsula el concepto de interacción espacial propuesto en la década de cuarenta Zipf (1949) y Stewart (1950) aplicaron el concepto a una amplia variedad de fenómenos (migración, tráfico de mercancías, intercambio de información) utilizando una forma simplificada de la ecuación de gravedad:

$$T_{ij} = \alpha \frac{p_i p_j}{d_{ij}} \quad (13.1)$$

donde T_{ij} es la interacción entre los centros i y j , p_i y p_j son las respectivas poblaciones, d_{ij} es la distancia y α es una constante de equilibrio. En el modelo, la población inicial, P_i , se denomina producción mientras que la segunda población, P_j , se denomina atracción.

Aunque esta idea se originó en el campo de la Geografía Humana, tomó inspiración de la Física newtoniana y otorga una base empírica a las interrelaciones locales presentes en el espacio geográfico (Cordozo y Da Silva ,2015).

La heterogeneidad del espacio geográfico ocasiona una serie de procesos y conexiones que interrelacionan las diversas ubicaciones de manera horizontal, un fenómeno denominado interacción espacial. La distancia juega un papel crucial en la intensidad de estas interacciones, ya que simboliza la separación entre diferentes puntos o entidades (Halás et al., 2014).

El efecto de *distance decay* es un principio que relaciona ubicaciones, flujos y las distancias entre ellos. Se refiere al efecto decreciente que la distancia tiene en la interacción espacial, observable empíricamente en diversas entidades. Esta idea, sólidamente arraigada en teoría, puede aplicarse en múltiples campos donde la distancia actúa como una variable clave para explicar la

distribución y relación de ciertos fenómenos. Así, diversas disciplinas han adoptado el concepto de *distance decay* para analizar y entender la distribución de fenómenos.

Este concepto hace referencia a la proximidad entre el origen y el destino, y es inversamente proporcional a la distancia espacial de separación entre el origen y el destino.

Sustentada en los modelos gravitacionales, la función *distance decay* queda definida matemáticamente como:

$$I_{ij} = \alpha_i m_j^{-\gamma} d_{ij}^{\beta_i} \quad (13.2)$$

Donde I_{ij} es la interacción entre el origen i y el destino j ; m_j es el atractivo de j ; d_{ij} es la distancia (o coste de interacción) entre i y j ; y α_i , γ , β_i son parámetros del origen donde β_i es conocido como el parámetro de origen específico de la *distancia decay* (Fotheringham, 1980).




Figura 13-1 Función negativa exponencial: JTC. Tomado del manual *Journey to crime estimation Crime Stat III*: (p.33) por Levine, 2004

La curva teórica representativa del efecto *distance decay* es una función exponencial negativa (véase Figura 13-1), donde se observa la disminución del grado de interacción con el aumento de la distancia, fenómeno considerado por Tobler (1970) en la formulación de la primera ley de la Geografía.

La percepción del individuo sobre la eficacia de un servicio disminuye conforme aumenta el tiempo de desplazamiento necesario para acceder a él. Dentro de la geografía de los servicios, la distancia de decaimiento se reconoce como un elemento esencial en el análisis espacial.

El concepto *distance decay* se presenta como una robusta concepción teórica factible de ser extrapolada a diversos campos, dentro de los cuales, la distancia es una variable por considerar como explicativa de la distribución y asociación de un determinado fenómeno.

Conceptualmente, se define como la resistencia o impedimento que la distancia impone sobre las interacciones espaciales entre dos entidades. Esta característica la establece como un fenómeno a escalar, permitiendo su aplicación a diversas temáticas en múltiples contextos y marcos temporales (Eldridge y Jones, 1991).

El concepto del decaimiento de la distancia se basa en la tendencia observada de que los delincuentes suelen cometer la mayoría de sus actos delictivos cerca de su lugar de residencia, disminuyendo la frecuencia a medida que se alejan. Así, a mayores distancias, se observa una menor incidencia delictiva. Esta tendencia puede visualizarse a través de una curva de decaimiento, que se construye al analizar y consolidar las distancias entre el hogar del delincuente y los sitios específicos de sus delitos (Phillips, 1980; Turner, 1969). Aunque la forma de esta curva suele ser consistente, es relevante destacar que las distancias promedio pueden variar dependiendo del tipo de delito (véase figura 13-1).

Ya en 1969, Turner planteó la hipótesis de que varias formas diferentes de función podrían caracterizar el decaimiento de la distancia en el comportamiento espacial delictivo. De hecho, Brantingham y Brantingham (1993), Canter et al. (2000), Kent (2003), Levine (2002), Phillips (1980), Turner (1969) proponen diferentes funciones de decaimiento que proporcionan las aproximaciones más cercanas para describir las distancias recorridas para delinquir para diversas poblaciones criminales.

De manera similar al análisis del delictiva, en la población general hay una alta correlación entre la distancia recorrida y la motivación asociada con un viaje determinado (Więckowski et al., 2012).

La función de decaimiento de la distancia, tal como se describe en Chainey y Ratcliffe (2005), es fundamental en las herramientas de software utilizados para generar mapas de probabilidad basados en teorías previamente establecidas. Esta función indica la probabilidad de que un delincuente se desplace cierta distancia desde su residencia hasta el lugar del delito, conocido como viaje hacia el crimen o "*journey to crime*" (en adelante JTC) en el ámbito anglosajón, un área de investigación criminológica que se interesa por las distancias que los delincuentes para cometer delitos, específicamente la distancia desde su domicilio hasta el sitio del delito. La mayoría de los delitos requieren la convergencia coincidente o planificada en el tiempo y lugar de los delincuentes motivados y los objetivos adecuados. La convergencia a menudo implica movilidad por parte del delincuente.

La relación entre las distancias recorridas por el delincuente y la cronología de los eventos es revisada por Snook, et al. (2005), en casos de asesinatos en serie. Se ha observado tanto una disminución como un aumento en las distancias desde la base de operaciones hasta los lugares del delito (Godwin y Canter, 1997; Rossmo, 2000) y encuentran una explicación lógica. Un aumento de las distancias recorridas podría explicarse por el miedo a ser reconocido, lo que lleva al infractor a alejarse de su punto de anclaje o en función de la alarma social creada por los medios de comunicación. Una disminución sería el resultado de una construcción de confianza, el delincuente asumiendo cada vez más riesgos.

O incluso, es posible que el delincuente ya estuviera involucrado en otras actividades delictivas antes, lo que influyó en su conocimiento de la ubicación del delito (Trotta et al., 2013).

Las zonas próximas a la residencia del delincuente suelen serle conocidas, dado que es habitual que las visite en sus actividades cotidianas no delictivas. Aunque esto no elimina la

posibilidad de que, ocasionalmente, el delincuente se encuentre distante de su hogar y opte por actuar delictivamente de manera impulsiva, la realidad es que moverse por zonas desconocidas en busca de oportunidades delictivas conlleva mayores riesgos y costos. Por tanto, estas circunstancias son menos frecuentes. De este modo, es razonable deducir que a medida que aumenta la distancia entre el sitio del delito y el hogar del delincuente, disminuye la probabilidad de que actúe en dicha área.

Existe un efecto adicional relacionado con la teoría de la elección racional que influye en la forma de la curva de decaimiento por distancia en el caso de los delitos (Ratcliffe, 2006). En las inmediaciones del lugar de residencia (figura 13-2), los delincuentes deberían cometer delitos con menos frecuencia. En última instancia, desde una distancia de cero, la función de decaimiento por distancia será una función de distancia creciente hasta cierta distancia B . En el punto B , la función asume un máximo, pero a partir de ahí es una función decreciente. El área desde cero hasta la distancia B se llama zona de amortiguación. En tales situaciones, la distribución de JTC ya no se parece a una distribución exponencial, sino que es más log-normal o incluso normal. Cabe señalar que esto no significa que los eventos a una distancia determinada no ocurran en absoluto, sino solo que la probabilidad es menor. La forma final de la curva de decaimiento por distancia se muestra en la figura 13-2.




Figura 13-2: Función decaimiento con la distancia con zona de amortiguación. Tomado *The distance covered by perpetrators and Their behaviour at The scene of The incident in The case of burglaries and robberies* (p.29) por Górski, 2018b.

La función de decaimiento de la distancia que se describe actúa como base en los programas diseñados para asistir en la creación de perfiles geográficos, tal y como señalan Chainey y Ratcliffe (2005). Estos programas superponen un esquema sobre el mapa, cuyos valores fluctúan en función de la distancia a los lugares de los incidentes, relación que se articula mediante la función JTC. Es interesante destacar el enfoque de Rossmo (2000), cuyo algoritmo difiere ligeramente: en lugar de usar una curva de decaimiento de la distancia obtenida estadísticamente, emplea una función diseñada específicamente, reservando el uso estadístico para determinar los valores de ciertas constantes. Un aspecto crucial del algoritmo de Rossmo es que siempre considera la presencia de una zona de

seguridad (Un área centrada alrededor del domicilio de un delincuente dentro de la cual los objetivos se consideran menos deseables debido al riesgo percibido asociado con operar demasiado cerca del domicilio). Independientemente del enfoque, el resultado visual tiende a ser similar: se produce un mapa con una celda superpuesta, y cada celda de esta retícula representa la probabilidad de localizar al autor en esa área específica. La forma final de la función se muestra en la figura 13-3.




Figura 13-3: Función de probabilidad utilizada en el algoritmo de perfilado geográfico, que muestra la relación entre la distancia desde el punto de anclaje de un delincuente y el riesgo de victimización/depredación (Tomado de Rossmo, 2000). La zona de amortiguamiento (BZ) es un área de probabilidad de ataque reducida que rodea inmediatamente el punto de anclaje.

Con el fin de comprender mejor la confluencia de la víctima, del delincuente y del lugar, los investigadores han intentado comprender la interacción espacial de las personas en el espacio. Mientras que la idea de los viajes de los delincuentes a la delincuencia es relativamente simple, las implicaciones de dónde y por qué los delincuentes viajan a lugares específicos para cometer delito afecta a la mayoría de las teorías Criminológicas (Rengert et al., 1999).

Al analizar el viaje hacia el crimen, resulta relevante incluir componentes como la motivación del delincuente, el punto de origen, el destino, la ubicación del delito, la ruta seleccionada, el momento en que se lleva a cabo, la duración, la distancia recorrida, la dirección tomada, el medio de transporte empleado y si el desplazamiento se realiza en solitario o acompañado (Bernasco, 2012). No obstante, Rengert (2004) examina certeramente en su revisión bibliográfica que la mayoría de las investigaciones sobre el trayecto hacia el delito se centran exclusivamente en medir la distancia al delito, dejando de lado el punto de origen y los aspectos direccionales del desplazamiento.

Parece que el perfil geográfico simplifica en exceso una compleja interacción entre diferentes factores cognitivos, motivacionales, ambientales y otros factores correlacionados que afectan el comportamiento de los delincuentes.

Modelos matemáticos

Los modelos matemáticos para describir las funciones de disminución de la distancia juegan un papel importante en la elaboración de perfiles geográficos, y los programas de software diseñados para la elaboración de perfiles geográficos se basan en ellos.

Los sistemas de perfilado geográfico se están consolidando como herramientas esenciales en el ámbito investigativo, no solo por su función en la investigación, sino también por su capacidad para modelar y detallar el viaje al crimen. No obstante, aparte de Canter et al. (2000), ha habido escasa reflexión sobre cómo distintas funciones pueden influir en el rendimiento de estos sistemas y cuál sería el algoritmo matemático más adecuado para representar las frecuencias de desplazamientos hacia el lugar del delito.

Existen diversas funciones diseñadas para capturar de manera precisa las características observadas en el decaimiento de la distancia durante un viaje criminal, Brantingham, y Brantingham (1981) propusieron que una función normal atenuada podría representar este decaimiento tras una hipotética zona de amortiguación. Sin embargo, Rhodes y Conly (1981) destacaron que una curva exponencial negativa reflejaba un ajuste superior al caracterizar la distribución de eventos asociados con delincuentes seriales, ladrones y agresores.

Los modelos Rigel (Rossmo, 1997c), Dragnet (Canter, 1995) y CrimeStat (Levine, 2015) utilizan una función de disminución de la distancia, específicamente, el modelo (Rigel) usa una función de decaimiento de la distancia exponencial negativa truncada para calcular las distancias entre las celdas de la cuadrícula y las ubicaciones del crimen, mientras que el modelo (Dragnet), por otro lado, usa una función exponencial negativa, pero permite que varíe el coeficiente exponencial. Levine (2002) recopila una extensa variedad de enfoques teóricos y funciones matemáticas de modelado, incluyendo las curvas exponenciales negativas, normales, lognormales y truncadas negativas, en las que se pueden ajustar los parámetros. Cada función tiene particularidades que son pertinentes para los modelos de viajes al crimen. Por ejemplo, las funciones exponenciales negativas, normales, lognormales y truncadas describen cómo la actividad delictiva alcanza un máximo en una determinada distancia del refugio (punto de anclaje) y luego disminuye a medida que la distancia al origen se incrementa. Una función en particular, la exponencial negativa truncada, es frecuentemente empleada para ilustrar el efecto de la propuesta zona de amortiguación de Brantingham. El modelo de CrimeStat difiere de los dos modelos anteriores en que no es estrictamente hablando un modelo de perfil geográfico, sino más bien un modelo JTC.

La principal diferencia entre un modelo de elaboración de perfiles geográficos y un modelo JTC es que este último es un modelo estrictamente estadístico e ignora en gran medida el marco conceptual de la elaboración de perfiles geográficos. Esto no quiere decir que los dos modelos sean diferentes en sus cálculos y supuestos básicos. De hecho, Crimestat contiene cinco funciones de decaimiento de distancia diferentes entre las que un usuario puede elegir realizar perfiles, incluyendo una exponencial negativa y una exponencial negativa truncada, tal como la utilizan Dragnet y Rigel, respectivamente (Paulsen, 2006).

El desarrollado por Rossmo (2000) funciona de manera ligeramente diferente: en lugar de una curva de decaimiento de distancia calculada estadísticamente, utiliza una función creada especialmente, y solo los valores de ciertas constantes se determinan estadísticamente. Lo significativo es que el algoritmo de Rossmo siempre tiene en cuenta la existencia de una zona de amortiguamiento (Chainey y Ratcliffe, 2005). La formulación matemática se detalla en la figura 13-4 (Modelo Rossmo).

Criminal Geographic Targeting (CGT)
Punto Geográfico Criminal

$$p_{i,j} = k \sum_{n=1}^{(\text{total crimes})} \left[\frac{\phi}{(|X_i - x_n| + |Y_j - y_n|)^f} + \frac{(1-\phi)(B^f - f)}{(2B - |X_i - x_n| - |Y_j - y_n|)^g} \right], \text{ Where } (X_i \neq x_n) \wedge (Y_j \neq y_n)$$

The diagram includes the following annotations:

- Factor de ponderación**: Points to the variable ϕ .
- Exponentes de fricción**: Points to the variables f and g .
- Probabilidad de que en el punto viva el delincuente**: Points to the variable ϕ .
- Constante determinada experimentalmente como un factor de normalización**: Points to the variable k .
- Radio de la zona Buffer de aproximación**: Points to the variable B .
- Distancia MANHATTAN**: Points to the Manhattan distance terms in the denominator.

The definition of ϕ is:

$$\phi = \begin{cases} 1, & \text{if } (|X_i - x_n| + |Y_j - y_n|) > B \\ 0, & \text{else} \end{cases} \iff (X_n, Y_n) \in B$$

Figura 13-4: Modelo de ecuación de Criminal Geographic Targeting (CGT).

Las funciones de decaimiento juegan un papel importante en la elaboración de perfiles geográficos, la función de disminución de la distancia se refiere a la relación entre la probabilidad de cometer un delito y la distancia desde el domicilio (Canter et al., 2000). Más específicamente, a medida que aumenta la distancia desde el domicilio de un delincuente, la probabilidad de que cometa un delito disminuye.

Por lo tanto, la importancia de las hipótesis presupuestas por diferentes funciones de decaimiento puede probarse comparando cómo se desempeñan los sistemas de perfiles geográficos cuando se incorporan diferentes funciones en los cálculos que utilizan para modelar el comportamiento espacial de los infractores.

Esta técnica de elegir parámetros de disminución de la distancia para optimizar la efectividad del perfil geográfico fue utilizada anteriormente por (Canter et al. (2000). En su

estudio, examinaron una serie de modelos exponenciales negativos para el decaimiento de la distancia y luego consideraron variantes que incluían zonas de amortiguamiento. En total, evaluaron 285 funciones diferentes para determinar su eficacia como herramientas de elaboración de perfiles geográficos.

Canter y Hammond (2006) adoptaron un enfoque híbrido; seleccionaron cuatro modelos generales para la disminución de la distancia del atacante: logarítmico, exponencial negativo, cuadrático y lineal. Para cada modelo, obtuvieron los parámetros que describen el modelo ajustando la curva de caída a una colección de datos agregados. Cada función generó un algoritmo de perfil geográfico ligeramente diferente; compararon la efectividad de estos algoritmos.

Aunque todos estos enfoques del problema de la elaboración de perfiles geográficos seleccionan una función de disminución de la distancia, su enfoque, naturalmente, está en determinar la eficacia de los algoritmos de elaboración de perfiles geográficos, más que en el problema de estimar la distribución de delitos o la función de disminución de la distancia de un delincuente individual.

Funciones de decaimiento de la distancia

Comprender la estructura y patrones de los delitos cometidos por un individuo resulta esencial, no solo por su relevancia teórica, sino también debido a la importancia que posee en la evolución y mejora de algoritmos para el perfilado geográfico. Ante la magnitud y complejidad del desafío, la prioridad ha sido determinar la estructura y la naturaleza de la función que describe cómo decae la probabilidad de un delito conforme aumenta la distancia desde el domicilio del delincuente. La curva definida por cada función representa cómo la probabilidad de delinquir

cambia a medida que aumenta la distancia desde el punto de anclaje. Cada función incluye una o más variables, arbitrariamente elegidas o derivadas empíricamente, que afectan el tamaño, el gradiente y la pendiente de la curva. Cada función de disminución de distancia es una función de d_{ij} , la distancia entre el punto bajo evaluación y la escena del delito actual.




Figura 13-5: JTC. curva de decaimiento con la distancia. Tomado de manual CrimeStat IV: A Spatial Statistics Program for the Analysis of Crime Incident Locations, Version 4.0 (p.810) por Levine y Associates, 2013.

Levine aconseja ajustar los parámetros de dicha curva de decaimiento para que concuerden óptimamente con el conjunto de datos. Además, explica cómo CrimeStat puede ser utilizado para elaborar una función de decaimiento de distancia de carácter experimental, la cual se adapta de manera aún más precisa a los datos consolidados.

Por otro lado, Rossmo (1995a) señala que el valor del exponente de distancia ($f = 1.2$) se derivó de una formulación basada en el modelo gravitatorio ideado para describir la migración interprovincial de delincuentes fugitivos (Rossmo, 1987). La elección del parámetro para la zona de amortiguación B se realiza de manera heurística, basándose en la distancia media al vecino más próximo “*mean nearest neighbor distance*”. El Índice de Vecino más Próximo o NNI (Nearest neighbor index) es un cociente de dos medidas que compara la distancia entre los puntos más cercanos y la media de distancia aleatoria, permitiendo solventar algunos de los problemas asociados al análisis de cuadrantes. El valor que define el índice de vecino más próximo, se define como:

$$NNI = \frac{R_{obs}}{R_{exp}} \quad (13.3)$$

Si el índice resulta ser igual a 1, indica que la distribución se ajusta a una distribución aleatoria; si resulta ser mayor que a 1, existe tendencia a la dispersión y si es menor que 1, existe tendencia a la agregación espacial (*cluster*).

Si bien existen otras funciones de disminución de distancia, estas son las expresiones más utilizadas. Los investigadores continúan desarrollando nuevas funciones en un intento de adaptarse mejor al comportamiento de los delincuentes en serie (véase capítulo 3.1).

Cada una de estas funciones de decaimiento de distancia puede visualizarse junto con su respectiva distribución bidimensional de delitos, como se muestra en las figuras 13-6 a 13-12.

Para elaborar cada uno de estos gráficos, recurrimos a los parámetros estándar detallados en el manual de CrimeStat (Levine, 2010). Es importante señalar que en todas estas figuras, los ejes horizontales representan distancias en millas (O'Leary, 2011a).

La función lineal ha sido presentada como una representación válida de la relación entre la distancia desde el hogar y la frecuencia de delincuencia (Turner, 1969). Sin embargo, dado que la mayoría de las investigaciones proponen que la tasa de disminución probablemente cambiará, la función lineal puede considerarse como una forma de control experimental que hace menos suposiciones que las otras funciones más complejas.

$$f(d_{ij}) = A + B(d_{ij}) \quad (13.4)$$

Donde $f(d_{ij})$ es la probabilidad de que el delincuente cometa un delito en una ubicación determinada, d_{ij} es la distancia entre la residencia del delincuente y la ubicación i , A es el coeficiente de pendiente, (el valor predeterminado es 1.9), B es una constante, (el valor predeterminado es -0.06).

Linear Distance Decay of Levine; $A = 1.9$, $B = -0.06$

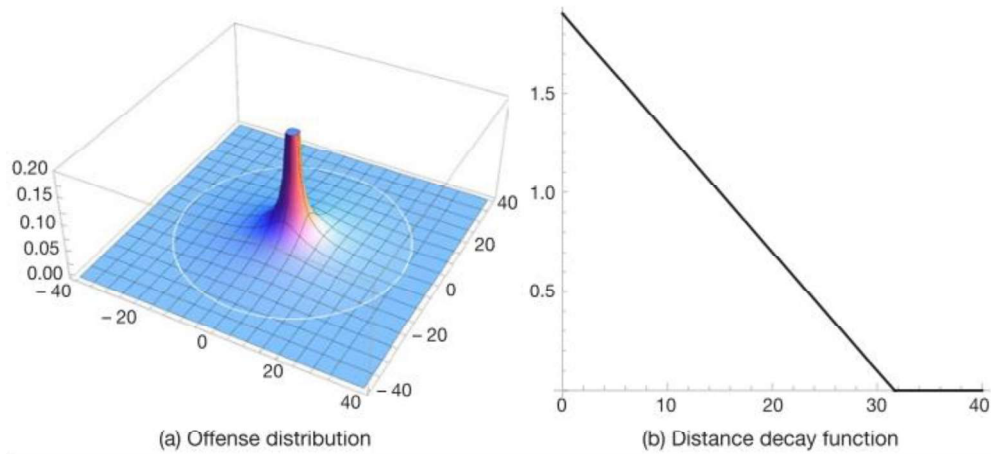


Figura 13-6: Distancia Lineal Nota: Tomado de Modeling Criminal Distance (p. 170) por O’Leary, Mike, 2011

La función negativa exponencial es un poco más compleja, este modelo describe cómo la ocurrencia de delitos es más alta cerca del refugio del delincuente y disminuye a una tasa constante con la distancia. La expresión matemática es

$$\rho_{Ct_j} = A \cdot e^{-Cd_i} \quad (13.5)$$

Donde ρ_{Ct_j} es la probabilidad de que un incidente ocurra en una ubicación particular, i , d_{ij} es la distancia entre cada ubicación de referencia y cada ubicación del delito, j , e es la base del logaritmo natural, A es el coeficiente, y C es el exponente. Esta función es muy similar al modelo Dragnet, excepto que el coeficiente está calibrado matemáticamente para la distribución

observada. Al igual que la función logarítmica mencionada anteriormente, asume que no hay una zona de amortiguación alrededor de la residencia del delincuente.




Figura 13-7: Negativa exponencial Nota: Tomado de Modeling Criminal Distance (p. 171) por O’Leary, Mike, 2011

La función de disminución de distancia normal también presenta un aumento inicial en la probabilidad de ofender que posteriormente disminuye con la distancia. Sin embargo, esta función usa la transición más suave de una curva normal. Al igual que la función exponencial negativa truncada, la función normal asume que existe una probabilidad máxima a cierta distancia establecida del punto de anclaje. La función se expresa como:

$$f(d_{ij}) = A \left(\frac{1}{s_d \sqrt{2\pi}} \right)^{-5} z_{ij}^2 \quad (13.6)$$

$$z_{ij} = \frac{d_{ij} - \text{Mean}D}{s_d} \quad (13.7)$$

Donde $f(d_{ij})$ es la probabilidad de que el delincuente cometa un delito en una ubicación determinada, d_{ij} la distancia entre la ubicación de referencia y la ubicación del delito, e es la base del logaritmo natural, A es un coeficiente derivado teóricamente (el valor predeterminado es 29.5), $MeanD$ es una distancia media derivada teóricamente (el valor predeterminado es 4.2), s_d es la desviación estándar de las distancias, Π es la relación entre el radio de un círculo y su perímetro (2.14159).

Normal Distance Decay of Levine; $A = 29.5$, $S = 4.6$, $\bar{r} = 4.2$

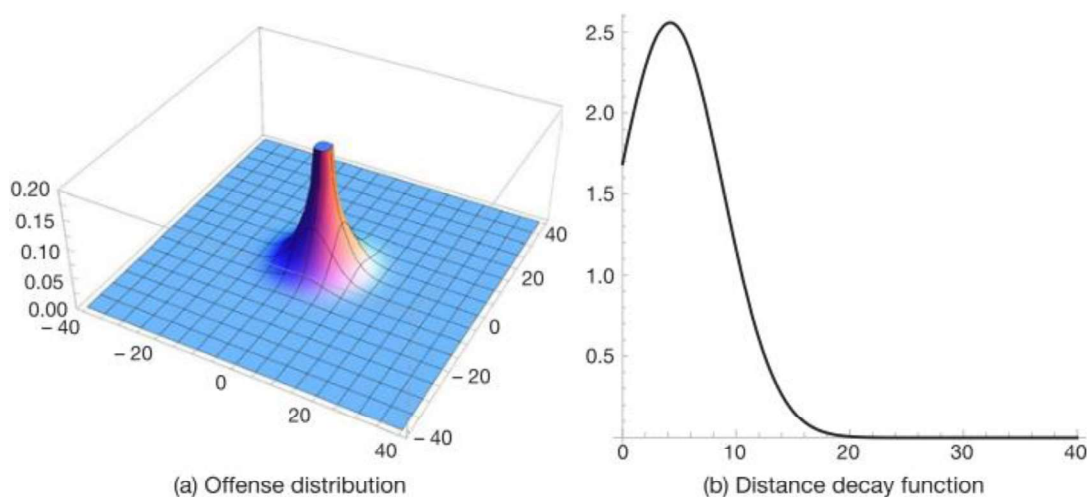


Figura 13-8: Distancia Normal. Tomado de Modeling Criminal Distance (p. 171) por O'Leary, Mike, 2011

La función lognormal es similar a la normal excepto que está más sesgada, ya sea hacia la izquierda o hacia la derecha. Tiene el potencial de mostrar un aumento muy rápido cerca de la base de origen del delincuente con una disminución más gradual desde un lugar de máxima probabilidad (ver figura 13-4). También es similar al modelo de Brantingham y Brantingham (1981).

La forma matemática de la función es:

$$f(d_{ij}) = \frac{A}{d^2 S \sqrt{2\pi}} \exp\left(-\frac{[\ln(d^2) - \bar{a}]^2}{2S_d^2}\right) \quad (13.8)$$

donde $f(d_{ij})$ es la probabilidad de que el delincuente cometa un delito en un lugar determinado, i , definido aquí como el centro de una celda de la cuadrícula, d_{ij} es la distancia entre cada lugar de referencia y la base del logaritmo natural, y A es un coeficiente (valor predeterminado 8.6).

Lognormal Distance Decay of Levine; $A = 8.8$, $S = 4.6$, $\bar{r} = 4.2$

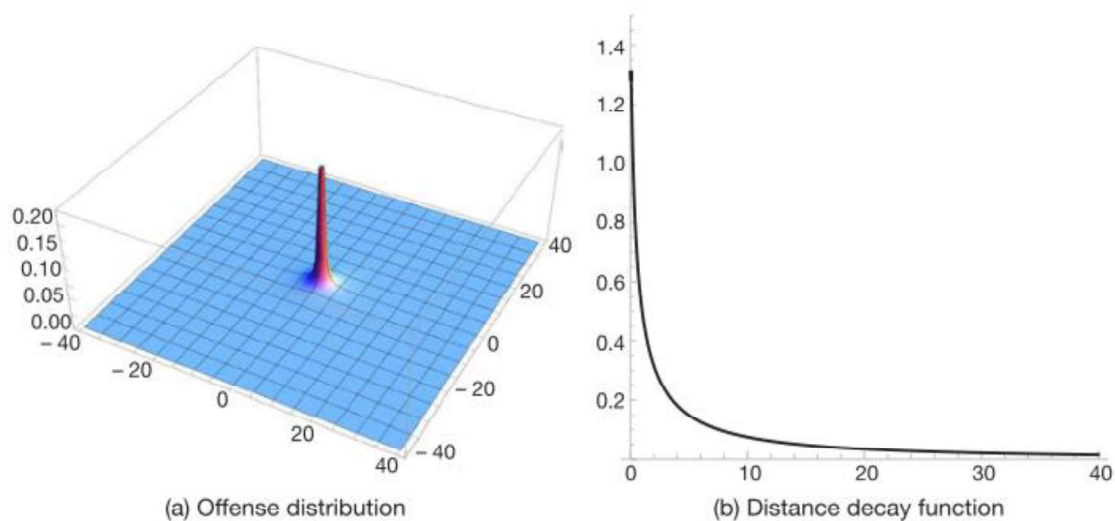


Figura 13-9: Distancia Lognormal. Tomado de Modeling Criminal Distance (p. 172) por O'Leary, Mike, 2011

Truncated negative exponencial, es una función compleja compuesta por dos ecuaciones

de decaimiento distintas: lineal y exponencial. Para ubicaciones cercanas a las residencias, se define una función lineal positiva. Comenzando en cero (el refugio) y aumentando hasta una distancia máxima, *Max d*. A continuación, la función sigue una función exponencial con signo negativo, disminuyendo rápidamente a medida que la distancia aumenta (ecuación 3 y 4).

$$\text{Lineal: } P_{ct_i} = A + Bd_i \quad \text{for } d_{ij} \geq 0 \text{ and } d_{ij} \leq \text{Max } d_{ij} \quad (13.9)$$

$$\text{Negativa exponencial } \rho_{ct_j} = A \cdot e^{-Cd_i} \quad \text{for } d_{ij} > \text{Max } d_{ij} \quad (13.10)$$

donde d_{ij} es la distancia desde el refugio, B es la pendiente de la función lineal, A es el coeficiente para la función exponencial negativa, y C es el exponente. Esta función es la aproximación más cercana al modelo CGT examinado anteriormente en el capítulo 2 (ecuaciones 2-7 y 2-8). Además, este modelo puede ser utilizado para aproximar el efecto de zona de amortiguación a menudo observado alrededor de la residencia de un delincuente.

Truncated Negative Exponential Distance Decay of Levine; $A = 14.95$, $B = 34.5$,
 $C = 0.2$, $r_p = 0.4$

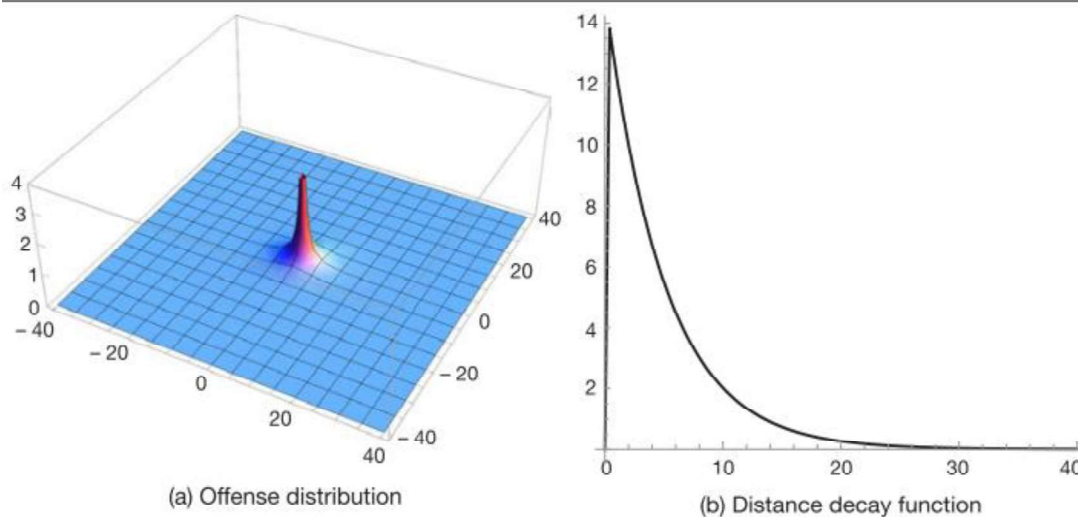


Figura 13-10: Truncada Negativa Exponencial. Tomado de Modeling Criminal Distance (p. 172) por O'Leary, Mike, 2011

Rossmo (1997) propone el algoritmo de focalización geográfica criminal que define explícitamente el área de amortiguación. Utiliza la media de las distancias al vecino más cercano para determinar el tamaño del área de amortiguación. Esto generalmente significa que cuanto menor sea la distancia media, más pequeña será el área de amortiguación. El algoritmo utiliza una métrica Manhattan.

$$P_{ij} = k \sum_{n=1}^C \left[\phi / (|x_i - x_n| + |y_j - y_n|)^f + (1 - \phi)(B^{g-f}) / (2B - |x_i - x_n| - |y_j - y_n|)^g \right] \quad (13.11)$$

$$\phi_{ji} = \{1, \quad (|x_i - x_n| + |y_j - y_n|) > B$$

$$\phi_{ji} = \{0, \quad \text{de lo contrario}$$

Donde;

ϕ funciona como un factor de ponderación que se establece en 0 para sitios dentro de la zona de amortiguamiento, y 1 para sitios fuera de la zona de amortiguamiento, k es una constante determinada empíricamente como un factor de normalización, ϕ_{ji} permite que P cambie entre los dos términos. Si ocurre un crimen dentro de la zona de amortiguamiento, entonces $\{\phi_{ij} = 0\}$ $\phi_{ji} = 0$, y, por tanto, el primer término no contribuye al resultado global. Esta es una prerrogativa para definir el primer término en el caso de que la distancia entre un punto (o celda) sea igual a cero. Cuando $\phi_{ji} = 1$ el primer término se utiliza para calcular P_{ij} , B es el radio de la zona de amortiguamiento, que equivale a la distancia media del vecino más cercano, C es el número de los lugares delictivos, g y f son exponentes de fricción determinados empíricamente, se determinó el valor del exponente de distancia ($f = 1.2$) a partir de una formulación de un modelo de gravedad para describir patrones de migración interprovincial de delincuentes fugitivos. En cuanto a la constante de escala multiplicativa k , su principal propósito es facilitar cálculos computacionales.

Rossmo Model; $f = g = 1.2$, $b = 0.3$, $k = 1$

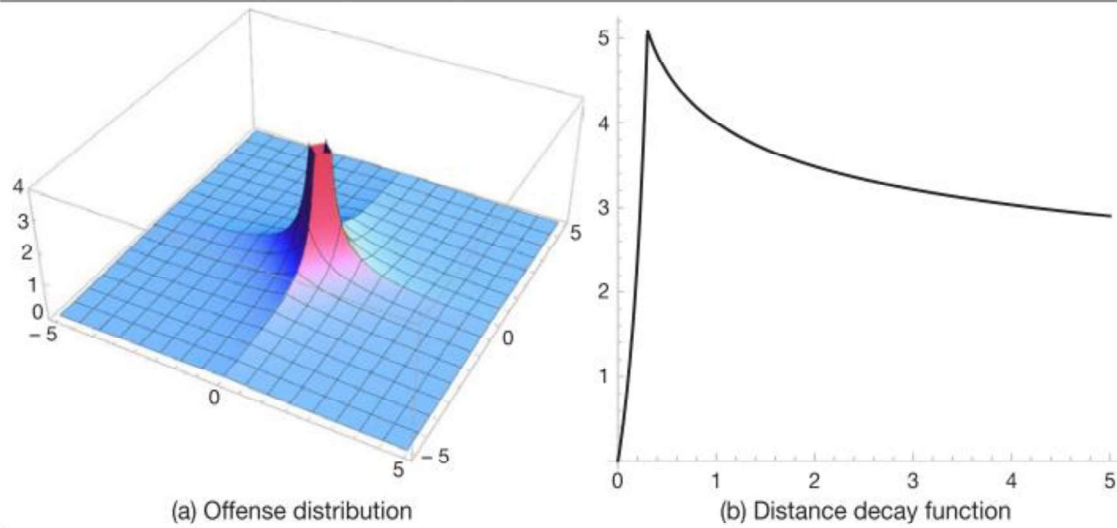


Figura 13-11: Rossmo Modelo. Tomado de Modeling Criminal Distance (p. 174) por O’Leary, Mike, 2011

La técnica empleada por Canter et al. (2000) para seleccionar parámetros de decaimiento de distancia, buscando optimizar la eficiencia del perfil geográfico, ha sido una referencia importante en el campo. En su estudio, analizaron diversos modelos exponenciales negativos y exploraron variantes con zonas de amortiguación y mesetas. En total, pusieron a prueba 285 distintas funciones en función de su utilidad en el perfilado geográfico (véase capítulo 3.1).

Posteriormente, Canter y Hammond (2006) propusieron un enfoque combinado. Identificaron cuatro modelos predominantes de decaimiento de distancia delictiva: logarítmico, exponencial negativo, cuadrático y lineal. Ajustaron cada modelo a un conjunto de datos agregados para determinar sus parámetros. Cada modelo resultante ofrecía una variante única del algoritmo de perfilado geográfico.

La función logarítmica, que muestra una representación aproximada de la distribución de las distancias en los desplazamientos asociados a delitos, señala que la incidencia de estos delitos disminuye notoriamente al inicio y luego de forma más pausada conforme se aleja de la residencia o punto de referencia del delincuente. A través de cálculos matemáticos, se determina una curva de ajuste que refleja cómo la tasa de cambio disminuye de forma acelerada y luego se nivela (Kent, 2003). Esta particular forma de decaimiento sugerida por la función puede tener su origen en los estudios de Stevens (1961) y su "Ley de Potencia" sobre estimaciones de magnitud, relacionándola con la probable percepción del delincuente sobre las distancias entre su hogar y los potenciales escenarios del crimen (Hammond y Youngs, 2011).

Hay un extenso corpus literario, siendo el artículo de 1961 de Stevens uno de los más destacados, que postula que las personas no hacen estimaciones de magnitudes de manera lineal. Esto implica que, conforme las magnitudes se incrementan, se requiere un aumento proporcionalmente mayor en la magnitud para lograr el mismo incremento en la percepción estimada. Stevens evidenció que la correlación entre la magnitud percibida y su tamaño real se define mediante una función logarítmica específica, dependiendo de lo que se esté estimando. Así, si se parte de la premisa de que los delincuentes evalúan la distancia a recorrer para cometer un delito, es lógico pensar que hacen una estimación sobre la duración o longitud de ese desplazamiento. Dicha estimación se vería influenciada por la función logarítmica propuesta por Stevens.

$$D(r) = \begin{cases} A + B \ln r & \text{if } A + B \ln r \geq 0 \\ 0 & \text{if } A + B \ln r < 0 \end{cases} \quad (13.12)$$

Donde:

$\ln r$ es un logaritmo natural de r

A y B son constantes con valores $A = 5.6735$ y $B = -1.3307$

Logarithmic Distance Decay of Canter and Hammond; $A = 5.6735$, $B = -1.3307$

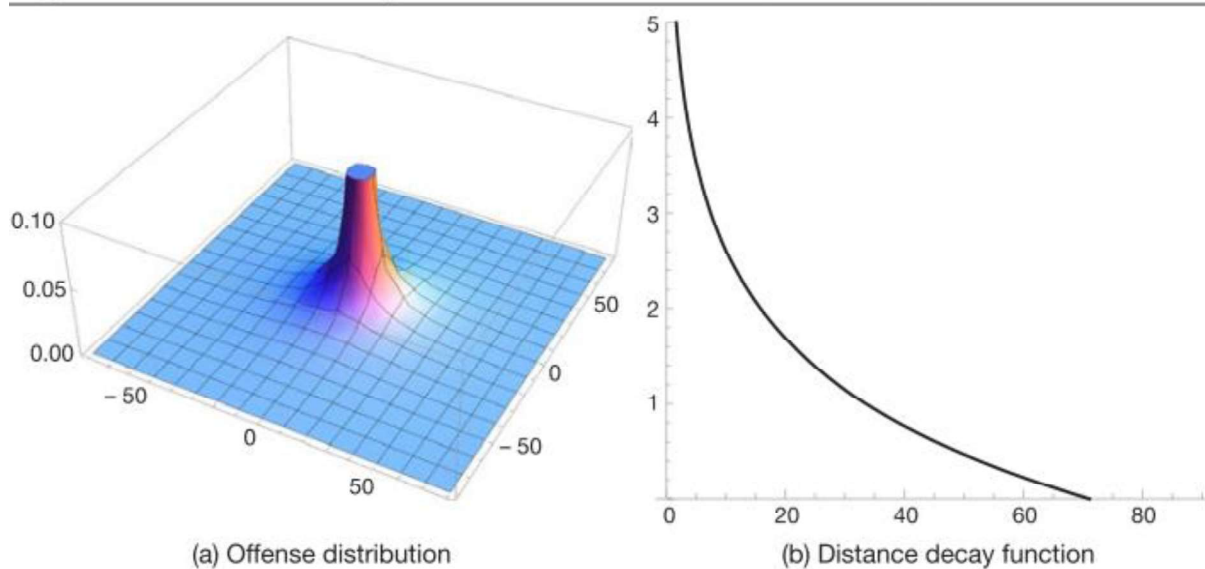


Figura 13-12: Distancia de decaimiento Logarítmico. Tomado de Modeling Criminal Distance (p. 175) por O'Leary, Mike, 2011

Limitaciones

La función de disminución de distancia, según (Chaeney y Ratcliffe, 2013), constituye en la práctica el componente esencial de los programas de software destinados al perfilado geográfico para elaborar mapas de probabilidad basados en las teorías previamente mencionadas. Esta función estipula la probabilidad de que un delincuente recorra una distancia determinada desde su lugar de residencia hasta el sitio del delito (JTC). Es probable que esta característica se refleje en casi todos los sistemas de perfilado geográfico que integran funciones de decaimiento.

Es plausible que diferentes funciones de decaimiento proporcionen lo mejor para diferentes subconjuntos infractores (Canter et al., 2000c). Sin embargo, como Capone y Nichols (1976) señalaron hace más de un cuarto de siglo, parece lógico suponer que diferentes funciones podrían proporcionar los mejores ajustes para distribuciones de distancia para diferentes tipos de delitos, y la investigación futura necesitaría determinar si este es de hecho el caso.

Sin embargo, la función de disminución de la distancia no está exenta de limitaciones;

1. La idea de que un delincuente posee una movilidad restringida, lo que da lugar al fenómeno de decaimiento por distancia, tiene aplicaciones significativas en al menos dos ámbitos. En primer lugar, es una herramienta valiosa para las organizaciones policiales en la creación de perfiles geográficos. A través de este método, se infiere la posible zona o punto central de operaciones de un delincuente basándose en la ubicación de varios de sus delitos (Rossmo et al., 2008; Rossmo, 2000; Van Der Kemp y Van Koppen, 2007). Con este objetivo, se han diseñado programas informáticos especializados. Sin embargo, el uso y eficacia de estos softwares han generado amplias discusiones en la comunidad (Alison et al., 2003; Canter y Hammond, 2006b; Paulsen, 2006; Snook et al., 2002; Snook, Zito, et al., 2005; Van Der Kemp y Van Koppen, 2007). Por otro lado, es importante mencionar que no todos los delincuentes siguen esta pauta. Algunos actúan como delincuentes viajeros (Canter y Larkin, 1993), cometiendo delitos lejos de su domicilio habitual, lo que complica aún más la tarea de generar un perfil geográfico preciso.

2. La función de decaimiento de la distancia se utiliza como modelo de comportamiento, según el cual la probabilidad de que un delincuente seleccione un lugar en particular para cometer un delito depende de la distancia entre ese lugar y su domicilio. Esto podría considerarse una descripción bastante restrictiva de la elección del lugar del delito por parte de los delincuentes. Un modelo más flexible mediría al menos la presencia de posibles objetivos y tendría en cuenta que, además de la distancia, los infractores deben tener en cuenta otras características de los posibles objetivos, como el rendimiento esperado del delito y el riesgo de ser detenidos (Bernasco, 2007).
3. Los métodos de reducción de la distancia pueden variar según la elección de la forma de función de decaimiento de la distancia que se utilizará. Una función de decaimiento de la distancia ampliamente utilizada es una distribución log-normal (Goodwill et al., 2014). Por su parte, Canter (2000) opta por emplear una función exponencial negativa truncada para este propósito. Mientras que Rossmo (2000) utiliza una función de distribución normal.

Además de estas funciones, las funciones lineales y exponenciales negativas son otras variantes de una función de disminución de la distancia. Basándose en la distribución de las distancias de viaje, tanto Rossmo (2000) como Canter (2000) se ha trabajado en determinar cuál es la forma óptima para la función de decaimiento de la distancia. Calibrar esta función puede ser beneficioso ya que permite adaptarla para que se ajuste de manera más precisa a los delincuentes locales (van der Kemp, 2014).

4. Los modelos no son conscientes de los patrones de otros delincuentes más que a través de la elección de la función de disminución de la distancia; en el caso de la función CrimeStat, se establece el modelo calibrándolo contra una muestra conocida y luego aplicando esa función al caso particular (Levine, 2005). Sobre la base de datos empíricos de distancias de viaje de infractores anteriores, se pueden estimar los parámetros de la función de disminución de distancia que mejor se ajustan a esas distancias de viaje. A través de esta calibración, se puede establecer una función que refleje mejor el comportamiento de viaje del tipo de delincuente a perfilar (Canter y Hammond, 2006). Sin embargo, en el caso de la calibración, el éxito también depende del supuesto de que el delincuente que se va a perfilar muestra un comportamiento similar al de los perpetradores utilizados para la calibración.
5. La función de disminución de la distancia es solo una imagen agregada y burda de las actividades delictivas. Van Koppen y De Keijser (1997) argumentaron que la función de disminución de la distancia podría surgir simplemente debido a cómo se agregan los datos. Ilustraron esto con un modelo en el cual cada delincuente tiene un rango específico de operación alrededor de su lugar de residencia. Si consideramos que los delincuentes actúan al azar dentro de sus respectivos rangos y que aquellos que cometen un tipo específico de delito tienen rangos de operación variados, se generará automáticamente una función de disminución de la distancia cuando se observen los datos en conjunto. Esto se debe a que, a corta distancia, casi todos los delincuentes son contabilizados en la distribución general, mientras que,

a distancias mayores, menos delincuentes son considerados en la misma. Por consiguiente, la existencia de una función de disminución de la distancia a nivel agregado no implica necesariamente que cada delincuente individual opere según esa misma función.

6. Hay dos términos íntimamente relacionados con la distancia de decaimiento: impedancia y gradiente de la distancia.

Todos los métodos hasta ahora asumen que los posibles objetivos delictivos son distribuidos aleatoriamente en el espacio. Por supuesto, esto no es realista. Además, los métodos que hemos revisado hasta ahora presuponen que todas las direcciones desde el domicilio del delincuente tienen igual probabilidad de ser seleccionadas, lo cual dista de ser una suposición realista. El comportamiento delictivo en los viajes está influenciado por características geográficas, como mares, lagos, ríos y vías de comunicación terrestres. El comportamiento de los viajes también está influenciado por las fronteras sociales entre los barrios. De manera más general, los patrones de búsqueda de delincuentes no suelen estar distribuidos de manera normal o uniforme. En cambio, los viajes delictivos parecen estar determinados por la actividad cotidiana, la disponibilidad de objetivos y las condiciones geográficas y sociales. Los métodos actuales de elaboración de perfiles geográficos no incorporan estas peculiaridades e incluso parecen ignorarlas. Tradicionalmente, la disminución de la distancia se ha calculado utilizando la distancia en línea recta entre un origen y un destino, pero los modelos ahora a

menudo incorporan redes de carreteras y conceptos como el tiempo de viaje y diferentes tipos de viajes (Birkin et al., 2002) (véase capítulo 14).

7. En las herramientas de perfilado geográfico, cada conjunto de datos se trata como un conjunto de datos único y no está relacionado con otros datos. Es decir, los delitos del delincuente se consideran una serie única de eventos en los que solo se aplica una función de distancia de viaje, de tal forma que asumen que el comportamiento de viaje de todos los delincuentes es el mismo que el del delincuente individual (Rengert et al., 1999). Por tanto, los resultados a nivel de grupo se aplican a nivel individual. En términos metodológicos, esto también se conoce como falacia ecológica (Robinson, 1950).
8. La consistencia de la distancia se presenta cuando los delincuentes cometen delitos repetidamente en aproximadamente la misma distancia de sus domicilios. Aunque hay muchas docenas de estudios que abordan la distancia de delitos en general, solo hay tres estudios que realmente investigan consistencia de distancia en delincuentes en serie (Smith, Bond, y Townsley, 2009; Townsley y Sidebottom, 2010; Van Daele, 2010). Los tres estudios son notablemente similares en su conclusión de que los delincuentes son mucho más consistentes a distancia de lo que han supuesto quien interpretó la función de decaimiento de distancia agregada como un fenómeno individual. Indicativo de la consistencia de la distancia, la variación de distancia dentro del delincuente parece ser mucho más pequeña que la variación de distancia entre los delincuentes.

9. Los resultados de las funciones de disminución de la distancia parecen estar determinados por el patrón espacial de las localizaciones de las escenas del delito más que por la función de disminución de la distancia utilizada. Por ejemplo, las distancias entre las escenas del delito, los valores atípicos y el número de delitos en una serie, tienen más influencia en el perfil geográfico que el uso de las diversas funciones de disminución de la distancia. Sin embargo, además de estos métodos de reducción de distancia comúnmente utilizados, también existen otros métodos de elaboración de perfiles geográficos (véase capítulo 4), debido a que se presta mucha atención en la literatura a la función de disminución de la distancia, los otros métodos están algo en segundo plano (Biessels, 2017).

En relación a este último punto, Trotta et al. (2013), proporciona un árbol de decisión como instrumento para evaluar los riesgos asociados con un perfil geográfico que podría resultar ineficaz. Este árbol estructura las relaciones entre las limitaciones, factores y condiciones típicamente necesarias para formular una superficie de probabilidad efectiva, como la relación entre los delitos, la cantidad de ubicaciones delictivas, la distribución equitativa de objetivos y el JTC. Este instrumento está ideado para asistir a los investigadores al abordar un nuevo caso, ayudándoles a determinar si es conveniente o no proceder con la elaboración del perfil geográfico.

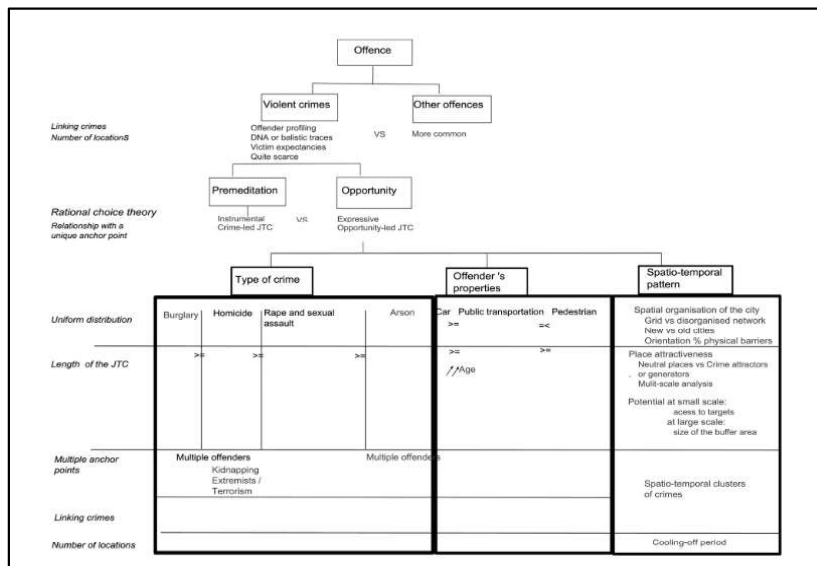


Figura 13-13: Un árbol de decisión para determinar las condiciones óptimas para construir un perfil geográfico. Tomado de Bulletin de la Socit Gographique de Lige (p.54) por Trotta et al., 2013.

Conclusiones

El delito no se distribuye aleatoriamente en el tiempo y el espacio (Brantingham y Brantingham, 1981; Cohen y Felson, 1979). Esta declaración puede actuar como una aparente excusa para el uso del perfil geográfico, pero las formas utilizadas actualmente del método tienen una precisión cuestionable, probablemente como resultado de simplificar en exceso las complejas relaciones entre los factores que influyen en la motivación, la planificación y la ejecución de delitos penales.

El perfil geográfico tiende a subestimar la complejidad de las interacciones entre múltiples factores cognitivos, motivacionales, ambientales y otros relacionados, que determinan el comportamiento del delincuente. Si bien hay múltiples documentos sobre el éxito de la perfilación geográfica, estos parecen estar sesgados hacia la divulgación de casos exitosos, omitiendo aquellos en los que el perfilado no ha sido efectivo. Así, es probable que los éxitos solo representen la punta del iceberg y que la mayoría de los perfiles geográficos sean menos reveladores.

En conclusión, la teoría del decaimiento de distancia parece una simplificación excesiva de las relaciones complejas entre muchos predictores que desempeñan un papel en los resultados del perfil geográfico. Paulsen (2007) advierte justificadamente que el perfil geográfico como método es demasiado amplio y no permite sacar conclusiones válidas porque no tiene en cuenta las redes de carreteras, densidad de población, y las zonas vacías tanto en tierra como en el agua. Por lo tanto, los cálculos de decaimiento de distancia proporcionan suposiciones arriesgadas, extraídas por los perfiladores de modelos matemáticos de una manera no crítica y selectiva para confirmar sus expectativas.

Aunque en el perfilado geográfico se utilizan diversas funciones de decaimiento de la distancia y los detalles en los cálculos pueden variar, es evidente que los resultados están más influenciados por el patrón espacial de los lugares donde se cometieron los delitos que por la función de decaimiento en sí. El resultado de la distribución de probabilidad basada en la función de decaimiento de la distancia es más sensible al número de puntos incluidos en un cálculo que a la fórmula de la función de decaimiento de la distancia de que se trate y de la variación de los parámetros de las funciones de descomposición de la distancia. Por este motivo, las distintas funciones arrojan aproximadamente la misma superficie. Aspectos como las distancias entre los

escenarios del crimen, que determinan el área de acción y búsqueda del delincuente, así como valores atípicos y la cantidad de delitos en una serie particular, tienen un impacto más significativo en el perfil geográfico que las variaciones en las funciones de decaimiento (Van Der Kemp, 2014).

Kent et al. (2006) en la investigación realizada a cabo, se examinaron dos funciones de decaimiento de distancia y se contrastaron cuatro métricas de distancia, buscando evaluar su efectividad en el ámbito del perfilado geográfico. Encontraron que la función exponencial negativa muestra una ligera ventaja sobre la exponencial negativa truncada. Este comportamiento podría estar relacionado con la falta de zonas de baja o inexistente actividad criminal cercana a las residencias de los delincuentes en el conjunto de datos utilizado. Es esencial seleccionar una función de decaimiento que represente de manera óptima la distribución espacial de los lugares del delito para garantizar la precisión en la creación de un perfil geográfico.

Otro aspecto esencial es la metodología empleada para medir el movimiento del delincuente desde y hacia el lugar del delito. Según nuestros hallazgos, los perfiles geográficos más precisos emergen cuando se cuantifican las distancias a través de métricas Euclidianas directas o trayectos indirectos tipo Manhattan. En contraste, al calcular distancias usando el recorrido más breve o rápido en una red vial, el área de búsqueda se expande hasta cinco veces en relación con las mediciones euclidianas o Manhattan.

A pesar de las diferentes fórmulas empleadas en el perfilado geográfico, el patrón espacial de los lugares donde se cometieron los delitos parece tener una influencia más determinante que la función de decaimiento misma. Esta observación sugiere que el comportamiento delictivo es más una representación del mapa mental del delincuente que de una ruta real tomada.

Un aspecto notable es que, para una cantidad pequeña de delitos, diversas funciones de decaimiento se adaptan adecuadamente al patrón existente y ofrecen soluciones similares. Esto indica que todos los métodos de perfilación geográfica dan prioridad a las escenas del delito en función de su proximidad a un punto de interés.

Bajo la premisa general de que los delincuentes tienden a actuar cerca de sus domicilios, se da mayor relevancia a los lugares del delito que están geográficamente más próximos entre sí. Por lo tanto, es más probable considerar esas zonas que las áreas más alejadas.

Debemos ser cautelosos al generalizar comportamientos individuales a partir de patrones grupales. Esto podría llevar a la falacia ecológica, asumiendo que lo que es válido para un grupo es igualmente válido para un individuo. Apoyando esta perspectiva crítica, Van Koppen y De Keijser (1997) sostienen que no es correcto concluir que un patrón observado a nivel grupal, como el decaimiento de la distancia, sea automáticamente aplicable a nivel individual.

Uno de los desafíos principales al abordar el comportamiento de decaimiento de distancia de un delincuente específico es la limitación en los datos disponibles. Las series de datos de un delincuente suelen ser limitadas y, aunque existen series con numerosos registros, los delincuentes que logran una larga serie de delitos podrían tener características únicas. Por lo tanto, estas series individuales no proporcionan suficiente información para hacer estimaciones fiables más allá de ciertos parámetros básicos, como el promedio y la desviación estándar de la distancia entre el punto de referencia del delincuente y los lugares donde cometió los delitos.

Basar una función de decaimiento de la distancia únicamente en las distancias entre delitos resulta ser un enfoque limitado. Tal como se refleja en investigaciones previas, el patrón espacial de las escenas del crimen es igualmente relevante (Canter y Larkin, 1993; Rengert, 2004; Rossmo,

2000). Es evidente que el entorno en el cual un delito es cometido influye en el comportamiento del delincuente. Esto, a su vez, puede generar variaciones en el comportamiento de desplazamiento entre diferentes delincuentes. Así, el patrón espacial de los delitos de distintos criminales puede variar notablemente. Dadas estas diferencias, es esencial considerar y analizar el patrón espacial de los delitos, como señala Van der Kemp (2014).

El árbol de decisión es una herramienta esencial para evaluar la eficacia de un perfil geográfico. A pesar de las técnicas convencionales, existen enfoques alternativos, como los métodos bayesianos, que no dependen de ciertas condiciones tradicionales. Estos métodos, como los propuestos por Levine y Lee (2009), o las estrategias que minimizan distancias y tiempos propuestas por Trotta, ofrecen nuevas perspectivas. Sin embargo, es crucial seleccionar una hipótesis espacial pertinente y desarrollar una metodología coherente. Las técnicas que no se centran en la domocentricidad, mencionadas por Canter y Youngs (2008), requieren más investigación y validación.

Aún queda por determinar si una mayor precisión en los datos y la implementación de modelos más elaborados podrían ofrecer mejoras significativas. Un modelo de tres funciones que tenga en cuenta a) los procesos cognitivos que influyen al delincuente, b) el esfuerzo requerido en el desplazamiento hacia el lugar del delito, y c) las oportunidades presentes y el atractivo del objetivo, podría ser esencial para representar de manera íntegra los desplazamientos de los delincuentes en relación con el acto delictivo.

Así pues, la distinción entre merodeadores y viajeros es más decisiva para determinar si un delincuente puede ser objeto de un perfil geográfico previo que el hecho de que cumpla o no el patrón de decaimiento de distancia (Biessels, 2017) (véase capítulo 12).

Capítulo 14

EL PERFIL GEOGRÁFICO: COMPORTAMIENTO Y ADAPTACIÓN AL MEDIO

Este capítulo se ha publicado como:

Salafranca, D., Rodríguez, S., & Mateu, J. (2020). El perfil geográfico: comportamiento y adaptación al medio. *International E-Journal of Criminal Science*, 15(2020), 1–27. <https://ojs.ehu.es/index.php/inecs/article/view/21533>

Indicio de calidad de la tesis doctoral (Artículo Científico) véase ANEXO F

Resumen

No hay teorías geográficas directas que brinden explicación de la distribución espacial del delito, sino que se ha establecido un vínculo entre la geografía humana y la criminología como resultado del desarrollo del fuerte paralelismo existente. En este contexto no tenemos constancia de la existencia de investigaciones que hayan comprobado la eficacia de la variable de distancia en modelos probabilísticos de perfilado geográfico. Una primera cuestión importante para los algoritmos de perfilado geográfico es determinar la métrica apropiada para medir la distancia, considerando que su comportamiento y adaptación al medio es fundamental para salvar los

obstáculos del entorno. En este sentido, el siguiente estudio tiene por objetivo explorar la influencia de los nodos y rutas en el marco de la llamada *journey to crime*, de los delitos realizados por Peter Sutcliffe (Yorkshire Ripper) entre los años 1975 y 1980, comparando tres medidas de distancia; directa (Euclidiana), indirecta (Manhattan) y distancias funcionales, concretamente métricas calculadas con el algoritmo Dijkstra's, con el fin de evaluar si la distancia seleccionada varía al aplicar una función exponencial negativa en un perfil geográfico.

Capítulo 15

EXPLORANDO LA CONSISTENCIA DIRECCIONAL

Resumen

Dentro del análisis espacial del delito, el proceso de toma de decisiones de los individuos involucra tres elementos interconectados y fundamentales: lugares, distancias y direcciones. Los dos primeros de estos elementos (lugares y distancias) están bien investigados dentro de la criminología. Sin embargo, existe una falta de consenso en la literatura criminológica sobre los métodos específicos para medir la consistencia direccional, un aspecto crucial en la comprensión del comportamiento delictivo. A pesar de esto, son limitados los estudios que se han enfocado en analizar la consistencia direccional en los delincuentes viajeros y merodeadores. En este capítulo, analizamos la consistencia de la direccionalidad comparando un conjunto de 531 delitos de 78 delincuentes de homicidios en serie (SHOs). La investigación estudia el comportamiento de la variable angular mediante la estadística circular (Rayleigh test). Encontramos pruebas de una fuerte presencia de direccionalidad en la toma de decisiones espaciales delictivas en el caso de viajeros (70% casos). Este aspecto de la espacialidad del delito debe considerarse en cualquier intento de comprender la clasificación del delincuente al realizar perfil geográfico.

Introducción.

La investigación sobre el comportamiento espacial del delincuente ha demostrado que la ubicación del delito y la elección de ubicación no son aleatorias, sino está involucrada alguna forma de toma de decisiones o elección consciente o inconsciente (Youngs, 2008; Canter y Hammond, 2007; Lundrigan y Canter, 2001). Cuando los delincuentes eligen los lugares del delito, son influenciado por los mismos procesos universales que influyen en el comportamiento espacial de la vida cotidiana de las personas (Canter et al., 2000c; Canter, 2004; Synnott et al., 2016), que comúnmente es experiencia y conocimiento del área (van Der Kemp y van Koppen, 2007) , buscando las ocasiones menos peligrosas, que presenten la mayor facilidad y viabilidad para cometer los delitos, y descartan los escenarios considerados no favorables por la poca oportunidad de éxito en la comisión del delito.

Es un principio de la toma de decisiones espaciales en geografía que, en cualquier actividad dentro de nuestros entornos urbanos, asimilamos información sobre ese entorno que posteriormente influye en las decisiones (Lowe y Moryadas, 1975; Rengert et al., 1999; Wolpert, 1964). Para comprender estas decisiones es fundamental la premisa de que los individuos se adaptan a su estructura espacial urbana y que el individuo se relaciona personalmente con la estructura que habita. Por lo general, se supone que el centro del entorno de cada persona es el domicilio (Horton y Reynolds, 1971).

La teoría geométrica del delito investiga el comportamiento espacial del delincuente, un elemento implícito en este enfoque es la rutina individual que conforma la vida cotidiana, concepto clave para el perfilado geográfico. Las actividades cotidianas tienen lugar entre los nodos de actividad (hogar, lugar de trabajo, área de ocio) y las rutas entre estos nodos. Al moverse entre los

nodos, un individuo da forma a un espacio llamado espacio de actividad. Esto representa el área en la que el delincuente generalmente se da cuenta de sus actividades no delictivas. El delincuente construye su espacio de oportunidad para cometer delitos como un subconjunto de su espacio de actividad. Este espacio de oportunidad está formado por la distribución no uniforme de los objetivos, debido a la naturaleza restringida de nuestro entorno construido y temporal, tendemos a desarrollar rutas específicas entre destinos visitados con frecuencia (véase capítulo 1).

Daele y Bernasco (2012b), identifican tres dimensiones fundamentales del *Journey to crime*, que se caracterizan por su consistencia. Estas dimensiones son: el destino, la distancia y la dirección. El destino se refiere al lugar geográfico específico donde se comete el delito. Por otro lado, la distancia es medida como la línea recta entre el domicilio del delincuente y el destino del delito, siendo esta conocida como distancia euclidiana. La dirección, por su parte, representa el ángulo formado entre la línea de ataque local y un punto de referencia base.

Entre estas, el destino es considerado el aspecto más informativo, dado que engloba tanto la distancia como la dirección partiendo del domicilio del delincuente. La coherencia direccional es el tercer tipo de coherencia espacial y constituye el objeto central del presente capítulo.

Conforme a la terminología empleada por Daele y Bernasco (2012b), la coherencia direccional ocurre cuando un delincuente perpetra delitos de manera reiterada en lugares ubicados en la misma dirección desde su punto de anclaje principal, que normalmente es el domicilio del delincuente. Se ha teorizado que el hogar de un delincuente actúa como un punto de anclaje psicológico, ejerciendo influencia en sus movimientos geoespaciales y en su conducta delictiva (Canter et al., 2000c; Rossmo, 2000).

El presente estudio se enfocará en analizar cómo los SHOs emplean una zona específica para buscar y seleccionar a sus víctimas. Basándonos en este criterio, clasificaremos a los SHOs en merodeadores y viajeros.

La tipificación del comportamiento de desplazamiento del delincuente es fundamental para la creación de perfiles geográficos, herramienta esencial en la investigación criminal. Diversos autores, como (Canter y Larkin, 1993; Kocsis et al., 2002; Meaney, 2004), han señalado las significativas implicaciones que las diferencias entre merodeadores y viajeros pueden tener en la construcción del perfil geográfico de los delincuentes.

A pesar de que sigue existiendo debate respecto a las limitaciones exactas de la elaboración de perfiles geográficos, hay un consenso casi universal en que esta técnica debe aplicarse únicamente en series de delitos donde el delincuente actúa como merodeador, según coinciden (Laukkanen y Santtila, 2006; Rossmo, 2005; Snook, Cullen, et al., 2005).

La clasificación entre merodeador y viajero a menudo se reduce a un solo criterio geométrico simple, utilizando la hipótesis del círculo. Si el círculo que une los dos delitos más lejanos contiene la residencia del delincuente, el delincuente se clasifica como merodeador, de lo contrario, se le llama viajero. Este criterio es altamente dependiente de la distancia entre las dos ofensas más lejanas.

La clasificación dicotómica de los SHOs en merodeador o viajero es ampliamente citada y utilizada, es una clasificación que depende de la demarcación geográfica de su área de distribución y en ciertas ocasiones dependiendo de la consistencia direccional se puede determinar la tipología del delincuente.

Daele y Bernasco (2012) propone una clasificación basada en el sesgo direccional, identificando que hay infractores que se distinguen por poseer un alto nivel de coherencia direccional. Debido a que todos sus delitos se localizan en el mismo lado de su punto de anclaje, estos se clasifican como viajeros. Por otro lado, aquellos delincuentes que presentan una coherencia direccional más reducida cometen delitos en diversas direcciones alrededor de su punto de anclaje, razón por la cual se les categoriza como merodeadores. Esta clasificación aporta una perspectiva útil para entender los patrones de movimiento y acción de diferentes tipos de infractores.

Kent et al. (2006) propone una clasificación en la que sugiere que un delincuente merodeador perpetra delitos dentro de un espacio de actividad anisótropo, es decir, en el que la oportunidad para delinquir no se distribuye de manera uniforme. Este efecto anisotrópico puede ser evaluado mediante la comparación del ángulo de rotación de cada elipse con el ángulo de rotación de la media direccional de las características viales subyacentes que coinciden con las extensiones espaciales de las escenas del delito. La propuesta de Kent aporta un método adicional para analizar y entender la dinámica espacial de los delincuentes merodeadores, al considerar la distribución no uniforme de las oportunidades para cometer delitos en su área de actividad.

Aunque el componente direccional es un área poco investigada en la geografía de la delincuencia, y genera cierta controversia sobre cómo debe medirse el elemento direccional, encontramos la base teórica de la presencia de direccionalidad en la actividad delictiva en la investigación

Revisión literatura.

Siguiendo el trabajo inicial de Rengert y Wasilchick (1985), existe relativamente poca investigación sobre el uso de la estadística circular aplicado al comportamiento espacial direccional en la investigación criminológica.

En el campo de la criminología, se han desarrollado diversas pruebas estadísticas circulares. Por ejemplo, Rengert, George y Wasilchick, en su estudio de 1985, se centraron en investigar la presencia de direccionalidad en el comportamiento delictivo. Lo hicieron mediante el desarrollo de un innovador método de análisis transportador. Por otro lado, Reboussin et al. (1993) analizaron la direccionalidad de agresores sexuales, considerando la variación angular en los viajes secuenciales entre delitos. Godwin (2001) analizó el ángulo direccional entre los delitos de 96 asesinos seriales, obteniendo resultados que indican una tendencia del comportamiento espacial en forma de cuña. Lundrigan y Canter (2001) investigaron las ubicaciones de los lugares de abandono del cuerpo de las víctimas, localizando los cuerpos en dirección opuesta a la escena del crimen. En otros estudios, como los de Kocsis et al. (2002) y Lundrigan et al. (2009), calcularon la consistencia direccional como el ángulo más grande entre cualquier par de delitos de la serie, encontrado evidencia en ambos estudios de consistencia direccional al identificar un "corredor" bastante estrecho en la serie de sus delitos. Goodwill y Alison (2005) estudiaron el asesinato en serie, la violación y el robo con allanamiento de morada y compararon los ángulos entre dos sitios de ofensas subsecuentes dirigidos por el mismo delincuente. Observaron que el ángulo entre dos asesinatos consecutivos es generalmente más grande que para la agresión sexual y el robo. Esta observación se centró en la angulación secuencial, teniendo en cuenta solamente los ángulos entre pares de delitos consecutivos. Por su parte, Daele y Bernasco (2012), propusieron una medida

mejorada de consistencia direccional y empíricamente utiliza entre un conjunto de 268 ladrones en La Haya. En un estudio más reciente, Gamo et al. (2017) analizaron y confirmaron la consistencia direccional mediante la angulación media en el caso de los robos en viviendas en Japón.

No hay consenso en la literatura sobre los detalles de cómo se debe medir la consistencia direccional. Goodwill y Alison (2005), usan angulación secuencial, en la cual se toman los ángulos entre pares de delitos consecutivos en la serie. Lundrigan y Canter (2001), establecen que la hipótesis sobre la preferencia direccional del delincuente se puede probar mejor analizando los ángulos creados por el domicilio del delincuente y la ubicación de su delito, la hipótesis se confirma cuando el ángulo es menor de 90° . En otros dos estudios (Kocsis et al., 2002; Lundrigan y Czarnomski, 2006) la consistencia direccional se calcula como el ángulo más grande entre cualquier par de delitos de la serie. Frank et al. (2013), proponen usar el ángulo más pequeño que abarca un gran porcentaje de los delitos de la serie, mientras que Daele y Bernasco (2012), utilizan el ángulo promedio de todos los pares de delitos de la serie, independientemente del orden secuencial. Leitner et al. (2007), estudian la dirección angular de cada elipse de desviación estándar y la comparan con la media direccional lineal de la red de carreteras subyacente para determinar si la orientación de las elipses coincidía con la orientación del paisaje físico coincidente. O'Leary (2009), para comprobar si la distribución de los sitios delictivos sigue una distribución normal bivariado, considera que no debería existir dependencia angular en los resultados. Para medir ángulos, utilizan como referencia un eje desde el punto de anclaje del delincuente hasta el centroide de la serie delictiva.

Datos Circulares e Instrumento

En numerosas situaciones, los datos relacionados con la delincuencia se pueden representar mejor en un círculo unitario, en vez de en un espacio lineal. Estos datos delictivos circulares suelen manifestarse en forma de direcciones u orientaciones, aunque pueden abarcar cualquier tipo de información que presente una periodicidad funcional. Para el análisis de este tipo de datos, ya sean angulares o temporales, se recurre a la circular estadística. Esta rama de la estadística, herramienta matemática que se ha utilizado en el presente estudio, como principal fuente para realizar análisis estadísticos.

Los datos circulares, que incluyen mediciones de ángulos, direcciones u orientaciones, son un concepto clave en diversas disciplinas. Según Glimm (1996) y Mardia y Jupp (2000), estos datos se diferencian de los datos lineales en que se apoyan en el concepto del círculo unitario, en lugar de la línea real utilizada en estadística lineal, como destaca Lewis (2016). Las aplicaciones de los datos circulares abarcan campos tan variados como la neurociencia, ilustrado por Rutishauser et al. (2010), la criminología, como demuestran Brunson y Corcoran (2006), la ecología, referenciada por Ravindran y Ghosh (2011), y las ciencias sociales y geociencias, mencionadas por Ketelaar (2015)

En el contexto de la orientación, estos datos suelen seguir una distribución circular o distribución de von Mises, también conocida como distribución circular normal o distribución Tikhonov, se suelen representar sobre un círculo, cuyo centro en la siguiente investigación, será el punto de anclaje del SHO, que convencionalmente se asume que se encuentra en la dirección 0° . Esta dirección se suele representar en el punto “norte” del círculo; las direcciones 90° y 270° se

representan en los puntos “este” y “oeste” respectivamente; mientras que la dirección 180° se representa en el punto “sur”.

La exploración estadística más habitual de los datos circulares consiste en probar la hipótesis nula de que los datos están distribuidos uniformemente en todos los valores posibles alrededor del círculo (frente a alguna forma de concentración). El enfoque más común para probar esta hipótesis nula es la prueba de Rayleigh (Rayleigh, 1880). Aunque fue una de las primeras técnicas estadísticas circulares, la prueba de Rayleigh es la más potente para detectar algunas desviaciones unimodales de la uniformidad circular (Landler et al., 2020).

Software especializado.

Es importante destacar que el perfilado geográfico tiene limitaciones fundamentales y no resueltas, como la identificación del tipo de infractor (merodeador/viajero) al inicio de la investigación policial (véase capítulo 12). En la actualidad, el software de elaboración de perfiles geográficos Dragnet, Rigel, Predator y CrimeStat IV (véase capítulo 3.1), asumen un modelo de comportamiento de merodeador en su predicción del área de residencia más probable de un SHO, encontrando también en estas herramientas diferentes enfoques para medir el componente direccional;

Predator, implementa un modelo que parece explorar la distribución de los eventos delictivos desde posiciones angulares, modelando los desplazamientos delictivos mediante el empleo de dos teorías de ubicación y asignación que utilizan distancias medias entre puntos y en línea recta entre los sitios del delito. El algoritmo calcula la pendiente entre dos puntos utilizando la función Arctangente (Godwin, 2001).

CrimeStat IV , implementa un (*Correlated Walk Analysis, CWA*) herramientas que pueden ayudar a un analista a entender la secuencia de eventos secuenciales en términos de intervalo de tiempo, distancia y dirección. Dentro de CrimeStat, se encuentran tres funciones bajo la denominación CWA (Correlograma, Diagnóstico y Predicción). Las dos primeras asisten al analista en determinar si existen patrones que se repiten a lo largo del tiempo, la distancia o la dirección. Por otro lado, la tercera función posibilita que el analista estime el lugar y momento en que probablemente ocurrirá el siguiente suceso. Estas herramientas, por lo tanto, proporcionan un marco integral para analizar patrones de crimen y anticipar futuros incidentes.

Dragnet, dispone de un parámetro de normalización de la función de decaimiento denominado *Q-Range*, un índice que tiene en cuenta la asimetría en la orientación de los incidentes, se basa en los hallazgos de que el uso de carreteras y rutas de viaje por parte de los infractores será de importancia para la estructura de las ubicaciones de sus delitos. Por lo tanto, *QRange* se obtiene identificando el eje de regresión lineal dentro de una serie de delitos alrededor del cual puede ocurrir dicha estructuración. *Q-Range* es la media de las distancias perpendiculares desde cada sitio de infracción al eje de regresión

Objetivos e hipótesis

El objetivo es comprobar una metodología que permita establecer criterios para medir la consistencia direccional de los SHOs (merodeadores y viajeros), utilizando herramientas de la estadística circular (*Rayleigh's test*). Se pretende obtener una nueva variable espacial que se pueda

aplicar al perfilado geográfico y clasificar a un delincuente en merodeador o viajero durante una investigación policial.

Una vez realizado el planteamiento desarrollado en la primera parte de esta investigación, se formulan 3 hipótesis que vertebran este trabajo: (i) Los SHOs pueden ser clasificados como merodeadores o viajeros en función de la consistencia direccional conocida durante las series criminales. (ii) Utilizando variables que podrían estar disponibles durante una investigación, ¿en qué medida se pueden detectar la orientación de un sector del azimuth del punto de anclaje de un SHO?, (iii) Los SHOs con una consistencia direccional más débil cometen delitos en muchas direcciones diferentes alrededor de su punto de anclaje y, por lo tanto, se clasifican como merodeadores.

Metodología

Datos e instrumento

Se obtuvo una muestra de 531 delitos de 78 SHOs (ver datos sobre SHOs en el Anexo A).

El rango promedio del número de víctimas fluctuó entre 4 y 20 personas. De acuerdo con la clasificación del comportamiento de desplazamiento propuesta por (Canter y Larkin, 1993), el 74,35% de los asesinos se categoriza como merodeadores, mientras que el 25,65% restante corresponde a viajeros.

Para los propósitos de esta investigación, se ha matematizado automáticamente dicho planteamiento. Esto se realizó calculando la relación entre la distancia máxima existente entre la escena del crimen y la residencia del delincuente, y la distancia máxima entre los dos puntos más alejados dentro de la zona de actuación del delincuente. De este modo, se busca obtener una

perspectiva más precisa y matemática de los patrones de desplazamiento y comportamiento de los criminales involucrados.

Es posible que los enfoques basados en modelos para investigar la orientación circular rara vez se apliquen en el perfilado geográfico porque carecen de una ejecución conveniente en el software estadístico convencional. Para fomentar su uso, implementamos los paquetes “*circular* y *CircStats*” para su uso en el software estadístico R V.4.0.0 (x64) (véase capítulo 7.1) El código usado en R para la prueba de Rayleigh's y Moore se puede ver en el anexo I.

Estudio de caso

El estudio de casos constituye un campo privilegiado para comprender en profundidad los fenómenos criminológicos y el procedimiento realizado en el conjunto de datos. En esta investigación se ha seleccionado el caso de Peter Sutcliffe (véase capítulo 6.9.1).

Tabla 15-1

Peter Sutcliffe caso instrumental

Serie	Fecha	Latitud	Longitud	Ángulo [CMD]	Ángulo [Punto anclaje]
1	05/07/1975	53.871481	-1.897633	310.2	312.2
2	15/08/1975	53.734182	-1.864272	237.0	208.9
3	30/10/1975	53.822352	-1.544942	71.7	86.5
4	20/01/1976	53.809052	-1.531635	79.1	91.7
5	09/05/1976	53.836585	-1.503293	69.2	82.1
6	05/02/1977	53.833069	-1.499997	71.0	83.5
7	23/04/1977	53.810211	-1.767216	319.9	104.9
8	26/06/1977	53.818458	-1.535151	74.4	88.1
9	10/07/1977	53.787368	-1.726811	270.2	125.6
10	01/10/1977	53.461321	-2.273241	225.2	219.4
11	14/12/1977	53.812352	-1.539600	77.4	90.7
12	21/01/1978	53.797916	-1.762342	297.0	134.6
13	31/01/1978	53.649382	-1.779432	192.8	177.8
14	16/05/1978	53.453019	-2.257498	223.6	217.8
15	04/04/1979	53.713390	-1.874463	230.0	206.5
16	02/09/1979	53.789796	-1.761270	277.6	144.8
17	18/08/1980	53.808400	-1.672148	56.5	94.4
18	24/09/1980	53.817419	-1.580650	70.7	88.4
19	05/11/1980	53.673159	-1.828876	208.0	189.3
20	17/11/1980	53.823573	-1.579763	67.1	85.4

Nota: Punto de anclaje (latitud, longitud) 53.81376, -1.789933.
[CMD] (latitud, longitud) 53.756124, -1.73901

Procedimiento

Este modelo se estructura en cinco etapas fundamentales:

1. El primer paso consistirá en la implementación del algoritmo Centro de Mínima Distancia (en adelante CMD). Este algoritmo identifica el punto que minimiza la distancia total a todos los otros puntos, y se ha establecido como el mejor predictor de la ubicación de la residencia del delincuente, según Levine (2015). Paralelamente, Neldner (2015) recopila y destaca las opiniones de varios expertos sobre el CMD, enfocándose en aquellos que argumentan su alta eficacia en determinar la base de operaciones de delincuentes de tipo merodeador. Seguidamente, se calcularán los valores angulares (véase la figura 15-1 'Spyder_Attacks_CMD'). Además, los ángulos observados se presentan detalladamente en la tabla 15-1.

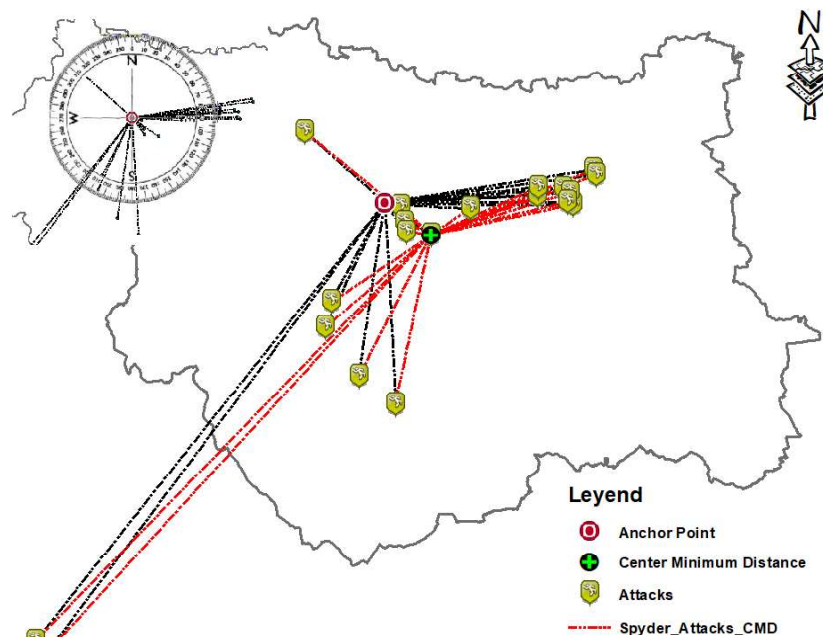


Figura 15-1: Spyder punto de anclaje y centro de mínima distancia de Peter Sutcliffe.

2. En el siguiente paso, se procederá a la creación del segmento entre el punto de anclaje (domicilio) y la ubicación de la víctima, obteniendo unos valores angulares de 0° a 360° , en la tabla 15-1 se detallan los ángulos observados
3. En la tercera parte se aplica la prueba *Rayleigh's* .

A pesar de que existen numerosas pruebas estadísticas para detectar la desviación de la uniformidad en los datos circulares, la prueba de *Rayleigh* es, con diferencia, la más común (Batschelet, 1981). Con la prueba de *Rayleigh*, la hipótesis nula es la uniformidad (es decir, ninguna dirección preferida), mientras que la alternativa es la unimodalidad (es decir, una única dirección preferida) (Mardia, 1972). La exploración estadística más habitual de los datos circulares consiste en comprobar si existe un sesgo en la distribución alrededor del círculo o si se apoya la hipótesis nula de que la población subyacente implica una distribución uniforme alrededor del círculo.

La prueba de *Rayleigh* se aplica calculando el rumbo medio de los ángulos ajustados mediante un procedimiento trigonométrico estándar para vectores de magnitud desconocida conocido como Prueba de Mardia o enfoque del promedio de vectores unitarios (Mori, 1987).

Seguidamente, se emplea la suma de todos los vectores unitarios con la finalidad de determinar un vector de dirección promedio para el conjunto de datos, denominado resultante media (r), a través de la ecuación de Pitágoras (Hewitt et al., 2018) . El procedimiento detallado se desarrolla de la siguiente manera:

En primer lugar, cada medida de orientación entre el punto de anclaje y los crímenes (θ) se trata como un vector unitario (v) con dirección θ y magnitud (m) =1 y se transforma en forma de componente (i, j) simplemente tomando $\cos \theta$ (i) y $\sin \theta$ (j). Todos los i y todos los j de cada vector se suman entonces para producir I y J como se muestra en las ecuaciones 1 y 2.

$$I = \sum_{x=1}^n m(\cos \theta_x) \quad (15.1)$$

$$J = \sum_{x=1}^n m(\sin \theta_x) \quad (15.2)$$

Posteriormente, se determina la media (r) de la siguiente forma:

$$I = \frac{\sqrt{I^2 + J^2}}{n} \quad (15.3)$$

Por último, el valor crítico de la prueba, o puntuación Z , se calcula mediante:

$$Z = nr^2 \quad (15.4)$$

Donde n es el número de observaciones y r es la media resultante calculada anteriormente. A continuación, se compara el valor Z con una tabla de valores críticos para la z de Rayleigh, como la que ofrece Zar (1999). La longitud del vector medio, r ,

proporciona información sobre si la muestra se distribuye uniformemente o, si, por el contrario, no lo hace. Si r es muy pequeño los datos están poco concentrados, eso significa que están distribuidos uniformemente. Por el contrario, si r es muy elevado los datos están concentrados con lo cual hay direccionalidad. La longitud del vector medio varía entre 0 y 1, valores superiores a 0.5 indican la agrupación de las observaciones alrededor del ángulo medio y la muestra es unimodal.

Tabla 15-2

Resultados de la prueba de Rayleigh para spyder ataques domicilio

SHO	Número observaciones (delitos)	Vector Medio (μ)	Leght Mean Vector (r)	Rayleigh Test (Z) $\alpha=0.05$	Rayleigh Test (p)
Peter Sutcliffe	20	126.526	0.5601	6.274	0.001

La prueba de Rayleigh se basa en una prueba de una hipótesis nula de uniformidad ($H_0: \rho = 0$ (Los ataques de un SHO se distribuyen uniformemente a lo largo del círculo), contra una hipótesis alternativa de unimodalidad ($H_A: \rho \neq 0$ (Los ataques del SHO NO se distribuyen uniformemente a lo largo del círculo).

Comprobamos que para un nivel de significación de $\alpha = 0,05$ y $n = 20$: $z_{0,05,20} = 2,958$. Al ser $z_{0,05} < z$ rechazamos H_0 , es decir, la muestra no se distribuye uniformemente a lo largo del círculo, por tanto, hay cierta direccionalidad. Se puede observar en los histogramas circulares de la Figura 15-2 (A y B) un vector medio de

126° (línea roja), el acimut puede clasificarse por sectores (SE) basándose en estas direcciones de la brújula (N, NE, E, SE, S, SW, W, NW).




Figura 15-2: Representación gráfica de la distribución que siguen los datos en el caso (A, B) desde el punto de anclaje a las víctimas y en el caso (C, D) desde el centro de mínima distancia a las víctimas

Para verificar la coherencia direccional, se empleó la prueba de Moore, que es una prueba no paramétrica para muestras pareadas diseñadas específicamente para datos circulares, siguiendo la metodología descrita por Zar (1999). Este proceso implica examinar las variaciones angulares entre la ubicación del domicilio y el centro de distancia mínima. El objetivo es determinar si existen diferencias estadísticamente significativas entre estas dos muestras y establecer la orientación azimutal del sector donde se localiza el domicilio con respecto al centro de mínima distancia, una variable que se dispone durante la investigación.

La significancia de los resultados se evaluó en un nivel de 0,05. Dos muestras de n_1 (series entre el domicilio y los asesinatos en grados, véase figura 15-2 (A and B), y n_2 (series entre el centro de mínima distancia y los asesinatos, véase figura 15-2 (C and D), valores angulares $\phi_1, \phi_2 \dots \phi_n$, que representan direcciones en un plano y cada valor se ha medido sobre el mismo SHO.

Prueba de Moore para dos muestras se basa en una prueba de una hipótesis nula en donde los datos se distribuyen uniformemente, (H_0 : Los ángulos del domicilio y del centro de mínima

distancia son iguales) contra una hipótesis alternativa (HA: Los ángulos del domicilio y del centro de mínima distancia son diferentes).

Tabla 15-3

Prueba de Moore para dos muestras y corrección Benjamin-Honchberg

SHO	Número de Observaciones (delitos)	Moore's PaireTest R' $\alpha=0.05$	Moore's Test (p)	Moore's Test (p) Benjamin-Hochberg $\alpha=0.05$
Peter Sutcliffe	20	2.109	0.0001	0.009

Como $R'_{0,05,20} = 1,024$ rechazamos H_0 , por tanto, concluimos que la dirección del domicilio y la del centro mínima distancia es diferente.




Figura 15-3: Visualizaciones de datos con un gráfico circular de datos. En negro ángulo del domicilio a las víctimas, en rojo ángulo del centro de mínima distancia a las víctimas

En el último paso, se implementará el procedimiento de corrección de Benjamini y Hochberg (1995). Este procedimiento aborda un desafío común en la investigación científica: el aumento del error de tipo I (*P-value*) causado por realizar múltiples comparaciones estadísticas. Este problema puede llevar a la publicación y promoción de resultados incorrectos, lo que subraya la necesidad de un ajuste meticuloso. Para obtener conclusiones estadísticamente confiables, es crucial tener en cuenta el número total de pruebas estadísticas realizadas y ajustar consecuentemente los niveles de confianza. Existen varias estrategias para enfrentar los problemas derivados de realizar múltiples pruebas de hipótesis, y la corrección de Benjamini y Hochberg es una de las metodologías más efectivas para este propósito

En el enfoque a este problema en la presente investigación, se ha optado por la corrección de Benjamini y Hochberg (1995), en lugar de controlar la probabilidad de uno o más errores de tipo I (es decir, rechazar H_0 cuando H_0 es verdadero) A lo largo del experimento, algunos de los enfoques más recientes respecto al problema de pruebas múltiples han enfocado sus esfuerzos en controlar la tasa de falsos descubrimientos (FDR, por sus siglas en inglés) en el experimento. Al regular la proporción de errores de tipo I, este enfoque tiene el beneficio de incrementar aún más la potencia estadística del algoritmo, resultando especialmente útil cuando se llevan a cabo numerosas pruebas de hipótesis. El método Benjamini-Hochberg (Masucci et al., 2014) se presenta como una técnica frecuentemente empleada para controlar la FDR en un experimento.

Resultado

Los resultados del estudio se resumen en la tabla 15-7. Los resultados reportados se refieren a promedios sobre $N = 78$ repeticiones en términos de rechazos correctos e incorrectos de hipótesis nulas a un nivel preespecificado de $\alpha = 0.05$ así como “*The false discovery rate*” (FDR).

Las orientaciones medias registradas desde el punto de anclaje a los delitos de los SHOs analizado, se pueden observar una muestra de 18 gráficas en la figura 15-4 y los resultados totales en tabla 15-7 en la cuarta columna (*Mean Vector*) y el en la quinta columna (*Sector compass*).

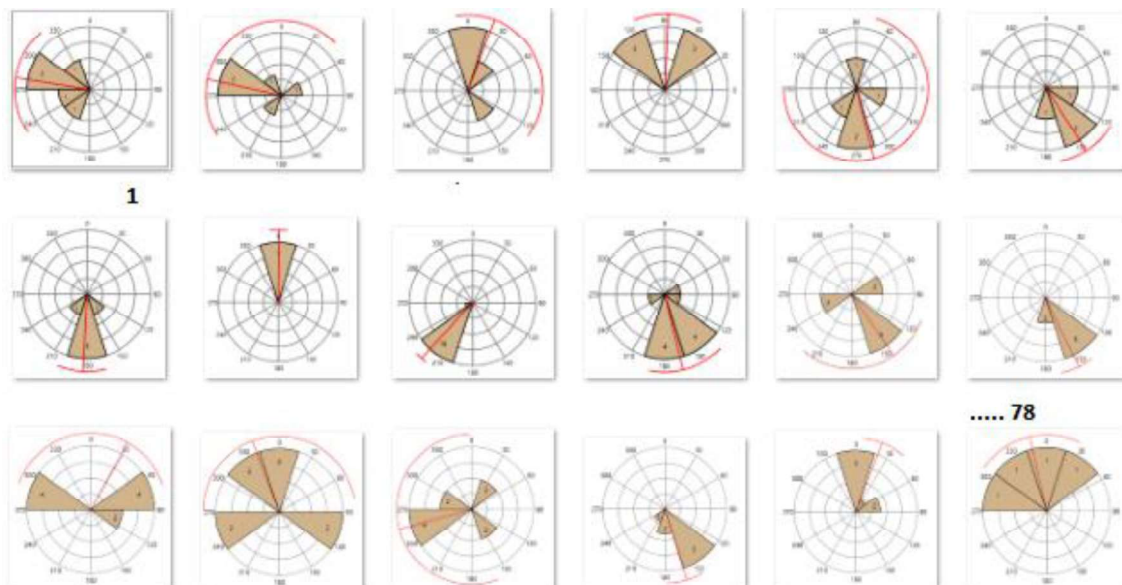


Figura 15-4: Diagrama de rosas de 18 SHOs. En cada sector se representan como un triángulo con un vértice en el centro y un número proporcional al número de observaciones.

Los resultados de las pruebas de Rayleigh en la tabla 15-7 indican en términos generales que los ángulos de los ataques del SHOs se distribuyen uniformemente en todas las direcciones.

En la figura 15-5 se observa la comparación de los resultados de los valores p no ajustados *Rayleigh's test* (A) punto de anclaje hacia los delitos y los valores p no ajustados *Moore paired test* (B) punto de anclaje ,centro de mínima distancia hacia los delitos y el método FDR (Benjamini - Hochberg = "BH")

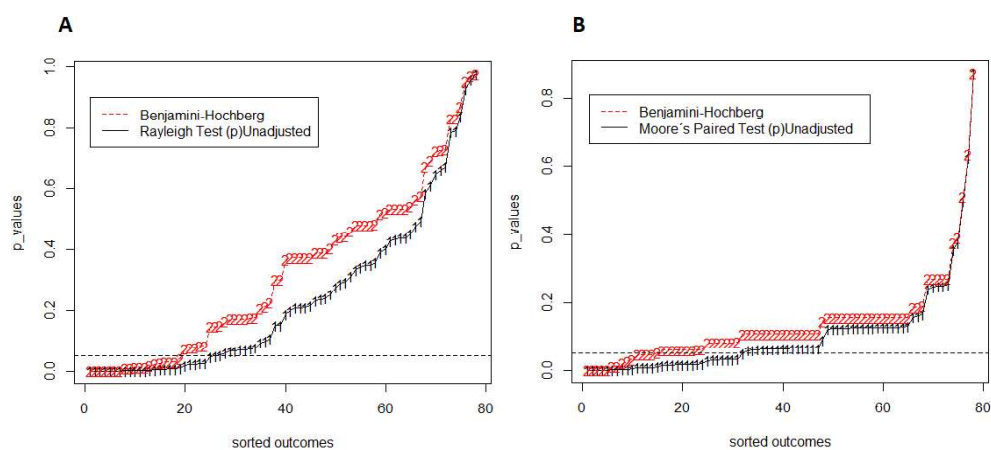


Figura 15-5: Comparación de los resultados de los valores p no ajustados y del método FDR (Benjamini / Hochberg = "BH").

Se compara el número de eventos significativos obtenidos si no se aplica corrección alguna ($=0.05$), con control BH para un FDR = 0.05 (véase tabla 15-4).

Tabla 15-4

Comparativa eventos significativos sin Corrección / Benjamin-Hochberg

Modelo	Sin corrección	Benjamini Hochberg
A (78)	26	19
B (78)	32	14

En la table 15-5 encontramos que los delincuentes viajeros no se distribuyen uniformemente a lo largo del domicilio, por tanto, hay consistencia en la direccionalidad (14 de los 20 delincuentes viajeros *Reject H₀*.)

Tabla 15-5

Resultados de la corrección (Benjamini / Hochberg) para la prueba de Rayleigh en el modelo (A). Proporción de viajeros y merodeadores.

SHOs	Reject H ₀	Not Reject H ₀
Merodeadores (58)	5 (8,62%)	53 (91,38%)
Viajeros (20)	14 (70%)	6 (30%)

En la tabla 15-6 encontramos que los resultados de las dos muestras para el modelo (B), los ángulos del domicilio y el centro de mínima distancia no son iguales en unos porcentajes de 82,85 para los merodeadores y un 85% para los viajeros. Con esta prueba se pretende determinar si hay diferencias entre los rangos angulares, al no rechazar H₀ (Los ángulos son iguales), los resultados obtenidos se alejan de la relación angular entre los dos puntos.

Tabla 15-6

Resultados de la corrección (Benjamini / Hochberg) para la prueba de pares de Moore en el modelo (B). Proporción de viajeros y merodeadores

SHOs	Reject H ₀	Not Reject H ₀
Merodeadores (58)	10 (17,2%)	48 (82,8%)
Viajeros (20)	3 (15%)	17 (85%)

Tabla 15-7

Estadísticas para la consistencia direccional de los SHO (Prueba de Rayleigh, Prueba de Moore, Benjamini y Hochberg)

Nº SHO	[C] [M]	(N)	Mean Vector (μ)	Sector compass	Rayleigh Test (Z) ($\alpha=0.05$)	Adjusted P-values Rayleigh Test (p) Benjamin- Hochberg ($\alpha=0.05$) Q-values	Rayleigh Test (p)	Rayleigh H_0 (Uniformidad)	Moore's Paired Test R' ($\alpha=0.05$) Q-values	Moore p	Adjusted P-values Moore's Paired Benjamin- Hochberg ($\alpha=0.05$) Q-values	Moore H_0
1	M	13	190.2	S	2.572	0.175	0.074	not rejected	1.274	0.002	0.015	rejected
2	C	7	133.8	SE	4.186	0.041	0.010	rejected	1.152	0.018	0.06	not rejected
3	M	5	278.7	W	2.711	0.164	0.059	not rejected	0.994	0.130	0.156	not rejected
4	M	6	282	W	1.589	0.374	0.211	not rejected	1.132	0.030	0.081	not rejected
5	M	4	20.8	N	1.277	0.462	0.314	rejected	0.981	0.127	0.156	not rejected
6	C	6	87.1	E	4.334	0.03	0.007	rejected	1.202	0.031	0.081	not rejected
7	M	5	284.5	W	0.964	0.524	0.403	not rejected	0.574	0.626	0.635	not rejected
8	C	4	147.8	SE	3.379	0.078	0.022	not rejected	1.07	0.121	0.156	not rejected
9	C	8	20.8	N	1.59	0.374	0.209	not rejected	1.232	0.007	0.046	rejected
10	C	5	183.1	S	4.377	0.026	0.005	rejected	1.158	0.062	0.108	not rejected
11	C	7	0.362	N	6.792	0	0.000	rejected	1.261	0.017	0.06	not rejected
12	C	20	222.3	SW	19.3	0	0.000	rejected	1.908	0.000	0.003	rejected
13	M	11	165.8	S	5.685	0.013	0.002	rejected	1.578	0.003	0.022	rejected
14	M	4	145.4	SE	1.162	0.48	0.335	rejected	0.947	0.247	0.27	not rejected
15	C	7	154.1	SE	6.42	0	0.000	rejected	1.311	0.014	0.06	not rejected
16	C	5	344	N	4.271	0.029	0.006	rejected	1.029	0.065	0.108	not rejected
17	M	5	28.839	NE	0.45	0.726	0.661	not rejected	1.321	0.064	0.108	not rejected
18	M	4	339.1	N	0.479	0.723	0.649	not rejected	0.984	0.125	0.156	not rejected
19	M	10	254.6	W	1.242	0.444	0.296	not rejected	1.094	0.028	0.081	not rejected
20	C	8	162.5	S	6.973	0	0.000	rejected	1.32	0.015	0.06	not rejected
21	C	8	20.89	N	1.59	0.374	0.209	not rejected	1.232	0.008	0.046	rejected
22	C	4	347.4	N	2.324	0.207	0.093	not rejected	1.094	0.125	0.156	not rejected

Nº SHO	[C] [M]	(N)	Mean Vector (μ)	Sector compass	Rayleigh Test (Z) ($\alpha=0.05$)	Adjusted P-values Rayleigh Test (p) Benjamin-Hochberg ($\alpha=0.05$) Q-values	Rayleigh Test (p)	Rayleigh H_0 (Uniformidad)	Moore's Paired Test R ($\alpha=0.05$)	Moore p	Adjusted P-values Moore's Paired Benjamin-Hochberg ($\alpha=0.05$) Q-values	Moore H_0
23	M	4	278.8	W	0.049	0.97	0.958	not rejected	0.753	0.498	0.511	not rejected
24	C	7	161.1	S	5.311	0.013	0.002	rejected	1.279	0.016	0.06	not rejected
25	M	4	296.2	NW	0.264	0.833	0.790	not rejected	0.69	0.376	0.391	not rejected
26	M	5	57.5	NE	1.704	0.367	0.188	not rejected	1.045	0.125	0.156	not rejected
27	M	6	13.2	N	0.869	0.534	0.438	not rejected	0.984	0.090	0.147	not rejected
28	M	4	85.5	E	0.902	0.534	0.434	not rejected	0.481	0.874	0.874	not rejected
29	M	11	297.5	NW	8.825	0	0.000	rejected	1.493	0.001	0.013	rejected
30	M	8	3	N	0.969	0.518	0.392	not rejected	1.158	0.123	0.156	not rejected
31	M	4	179.8	S	0.199	0.872	0.838	not rejected	1.158	0.128	0.156	not rejected
32	M	7	208.1	SW	2.847	0.15	0.052	not rejected	1.442	0.015	0.06	not rejected
33	M	5	222.4	SW	1.906	0.302	0.151	not rejected	1.212	0.061	0.108	not rejected
34	C	4	88	E	3.992	0.03	0.007	rejected	1.074	0.124	0.156	not rejected
35	C	4	242.8	SW	1.485	0.39	0.240	not rejected	1.044	0.125	0.156	not rejected
36	M	5	207	SW	3.349	0.084	0.026	not rejected	1.192	0.065	0.108	not rejected
37	M	4	158.2	S	0.766	0.576	0.495	not rejected	1.148	0.127	0.156	not rejected
38	M	6	335.4	NW	2.619	0.173	0.067	not rejected	1.177	0.033	0.084	not rejected
39	M	8	156.6	SE	2.59	0.173	0.071	not rejected	1.218	0.016	0.06	not rejected
40	M	9	107.7	E	0.558	0.672	0.586	not rejected	1.092	0.010	0.05	rejected
41	M	6	220.7	SW	2.62	0.173	0.067	not rejected	1.014	0.059	0.108	not rejected
42	M	13	77.1	E	3.556	0.084	0.025	not rejected	1.523	0.000	0.006	not rejected
43	M	4	301.6	NW	0.894	0.534	0.438	not rejected	0.969	0.254	0.271	not rejected
44	M	6	19.8	N	2.5	0.177	0.077	not rejected	1.167	0.062	0.108	not rejected
45	M	5	200.1	S	1.902	0.302	0.151	not rejected	1.044	0.126	0.156	not rejected
46	M	8	156.6	SE	2.59	0.173	0.071	not rejected	1.218	0.019	0.062	not rejected
47	M	6	119.2	SE	0.261	0.833	0.785	not rejected	0.861	0.157	0.186	not rejected
48	M	4	342.5	N	1.136	0.48	0.344	not rejected	0.849	0.249	0.27	not rejected
49	C	4	68.7	E	2.266	0.214	0.099	not rejected	1.132	0.123	0.156	not rejected
50	C	5	228.2	SW	4.917	0.009	0.001	rejected	1.112	0.058	0.108	not rejected

Nº SHO	[C] [M]	(N)	Mean Vector (μ)	Sector compass	Rayleigh Test (Z) ($\alpha=0.05$)	Adjusted P-values Rayleigh Test (p) Benjamin-Hochberg ($\alpha=0.05$) Q-values	Rayleigh Test (p)	Rayleigh H_0 (Uniformidad)	Moore's Paired Test R ($\alpha=0.05$)	Moore p	Adjusted P-values Moore's Paired Benjamin-Hochberg ($\alpha=0.05$) Q-values	Moore H_0
51	M	16	121.1	SE	1.623	0.374	0.199	not rejected	1.699	0.000	0.006	rejected
52	M	4	325.3	NW	1.493	0.39	0.238	not rejected	1.139	0.126	0.156	not rejected
53	M	6	247.1	SW	1.407	0.406	0.255	not rejected	1.233	0.031	0.081	not rejected
54	C	6	196.1	S	4.678	0.022	0.004	rejected	1.001	0.030	0.081	not rejected
55	M	9	108.7	E	5.164	0.018	0.003	rejected	1.539	0.004	0.034	rejected
56	M	6	74.9	E	1.494	0.39	0.233	not rejected	1.231	0.064	0.108	not rejected
57	M	5	154.2	SE	1.079	0.483	0.359	not rejected	1.074	0.063	0.108	not rejected
58	M	7	80.1	E	1.32	0.432	0.277	not rejected	1.021	0.049	0.108	not rejected
59	M	8	241.2	SW	2.913	0.147	0.049	not rejected	1.272	0.017	0.06	not rejected
60	M	4	224.9	SW	0.085	0.952	0.928	not rejected	0.824	0.249	0.27	not rejected
61	M	8	76	E	1.558	0.374	0.216	not rejected	1.332	0.007	0.046	rejected
62	M	5	315.4	NW	0.901	0.534	0.428	not rejected	1.146	0.062	0.108	not rejected
63	M	13	328.3	NW	2.986	0.147	0.047	not rejected	1.485	0.001	0.013	rejected
64	M	5	24.2	NE	0.43	0.729	0.673	not rejected	1.142	0.064	0.108	not rejected
65*	M	20	126.5	SE	6.274	0.009	0.001	rejected	2.109	0.000	0.003	rejected
66	M	5	147.6	SE	3.451	0.078	0.022	not rejected	1.156	0.065	0.108	not rejected
67	M	5	342.9	N	3.548	0.074	0.019	not rejected	1.149	0.125	0.156	not rejected
68	M	8	99.1	E	0.769	0.565	0.478	not rejected	1.303	0.008	0.046	rejected
69	M	16	21	N	9.06	0	0.000	rejected	1.845	0.000	0.003	rejected
70	M	9	5.3	N	1.079	0.48	0.350	not rejected	0.836	0.165	0.189	not rejected
71	M	7	168.2	S	1.276	0.442	0.289	not rejected	0.683	0.355	0.374	not rejected
72	M	5	267.3	W	0.53	0.692	0.612	not rejected	1.303	0.063	0.108	not rejected
73	C	6	313	NW	4.918	0.013	0.002	rejected	1.133	0.031	0.081	not rejected
74	M	4	341.1	N	2.2	0.226	0.107	not rejected	1.135	0.122	0.156	not rejected
75	M	5	136.9	SE	0.846	0.542	0.452	not rejected	0.864	0.246	0.27	not rejected
76	C	6	317.3	NW	5.696	0.003	0.000	rejected	1.072	0.062	0.108	not rejected
77	M	6	53.8	NE	1.091	0.48	0.351	not rejected	0.895	0.160	0.186	not rejected
78	M	5	53	NE	0.026	0.977	0.977	not rejected	1.01	0.127	0.156	not rejected

Conclusiones

Al abordar decisiones relacionadas con la delincuencia desde una perspectiva espacial, es crucial entender la influencia de la ubicación y la distancia para decodificar la naturaleza espacial de los incidentes delictivos.

Es ampliamente reconocido que la ubicación juega un papel vital en la predicción de la actividad delictiva. Al integrar en el análisis características como zonas de alta incidencia delictiva, nodos de actividad cotidiana o las rutas entre ellas, podemos obtener más respuestas al perfilado geográfico.

Se ha demostrado que los desplazamientos de los delincuentes no suelen tener una dirección aleatoria. De hecho, existe una tendencia en los delincuentes merodeadores de cometer delitos cerca de sus residencias, siendo aún más pronunciada esta tendencia en delitos violentos cometidos por SHOs. Para abordar sistemáticamente esta posibilidad, no basta con medir las distancias entre el domicilio y el delito, sino que también deben incluirse los ángulos de dirección, en futuros estudios.

La distancia no es el único factor crucial; la direccionalidad también tiene un papel determinante. Entender la direccionalidad nos ayuda no solo a asumir que un delincuente probablemente viva "cerca" del lugar del delito, sino también a inferir desde qué dirección podría provenir. Esta comprensión permite a los investigadores emplear su conocimiento local para anticipar la posible procedencia del delincuente.

En el marco de las ubicaciones, la direccionalidad también es útil para identificar lugares que actúan como generadores o atractores de delincuencia, según Brantingham y Brantingham

(1995) al rastrear la dirección predominante de la actividad delictiva, es posible identificar áreas emergentes como focos de delincuencia y, por lo tanto, priorizarlas en las estrategias de prevención.

Este estudio se centra en la prueba de hipótesis de consistencia de direccionalidad para los datos del movimiento desde el domicilio de los SHOs a la víctima. El objetivo principal era determinar si los patrones de movimiento direccional de los delincuentes merodeadores o viajeros eran uniformes.

Los resultados mostraron que los SHOs viajeros muestran una fuerte consistencia direccional, un 70% de los casos. Este hallazgo corrobora la hipótesis (i) en la que se puede clasificar en función de la consistencia direccional conocida durante las series delictivas, siendo interesante dicha clasificación para poder determinar el tipo de delincuente viajero antes de realizar un perfil geográfico, ya que es sumamente importante dada la incapacidad del software actual de elaboración de perfiles geográficos para perfilar con precisión las series de viajeros.

Estos resultados concuerdan con los descubrimientos de Daele y Bernasco (2012), en los que algunos infractores muestran una marcada coherencia direccional. Dado que todas sus infracciones se sitúan en el mismo lado de su punto de anclaje, se les categoriza como viajeros.

De acuerdo con la hipótesis (ii), encontramos que en un 84% aproximadamente para ambos delincuentes no pueden detectar la orientación acitumal del sector del punto de anclaje y del centro de mínima distancia de un SHO, no siendo un porcentaje adecuado para implementar el centro de mínima distancia, relacionado con la variación angular en el perfilado geográfico y su aplicación como centro angular.

Respecto a la hipótesis (iii), los SHOs con una consistencia direccional más débil cometen delitos en muchas direcciones diferentes alrededor de su punto de anclaje y, por lo tanto, se clasifican como merodeadores, este hallazgo corrobora la hipótesis (iii), los resultados obtenidos ofrecen que el 91% de los delincuentes merodeadores cometen delitos uniformemente alrededor del domicilio y están en línea con los hallazgos de Daele y Bernasco (2012), los delincuentes con menor coherencia direccional perpetran delitos en diversas direcciones alrededor de su punto de anclaje, siendo categorizados como merodeadores.

Si bien este estudio avanza en la literatura sobre la consistencia direccional de los SHOs y posibilita la identificación al inicio de una investigación a los delincuentes viajeros, el modelo tiene ciertas limitaciones.

Suponiendo que el proceso de toma de decisiones para cometer un delito comienza en el lugar de origen, el "viaje hacia el delito" puede ser relativamente corto. Esta suposición puede ser problemática porque el viaje hacia el crimen puede comenzar desde un lugar que no sea el hogar (Townsend y Sidebottom, 2010), y en los casos en el que el periodo de enfriamiento es superior a un día, el asesino regresa al domicilio siendo de nuevo la base para volver a la búsqueda de un nuevo objetivo, existe también la posibilidad de haber contabilizado la serie de forma errónea (el crimen 3 puede haber sido el 2), es por lo que usar una angulación secuencial, en la cual se toman los ángulos entre pares de delitos consecutivos en la serie, no parece el método correcto. Si este es el caso, gran parte de la inferencia basada en esta investigación puede ser engañosa. Sin embargo, esta suposición se realiza debido a limitaciones de datos.

En segundo lugar, el problema del método de clasificación merodeadores o viajeros, a pesar de sus consecuencias, es el que menos atención parece haber recibido por parte de la literatura o,

al menos, el que menos soluciones convincentes presenta, como advierten (Zhu y Zhang, 2012) ignora el efecto que podría tener un evento delictivo que ocurre cerca o incluso sobre el borde que separa a una unidad de análisis de la adyacente. Merece la pena recordar que esos límites creados de forma artificial no existen en la práctica, por lo que, si un incidente delictivo ocurre sobre el límite del círculo, dicho evento puede marcar la diferencia entre merodeador o viajero.

Capítulo 16

DISCUSIÓN Y CONCLUSIONES

La exposición del fenómeno del asesinato en serie al ámbito público, principalmente a través de la literatura y el cine, ha generado una fascinación cultural que ha oscurecido la gravedad y la realidad de estos crímenes. La representación de los asesinos en serie y de los agentes del FBI en las obras de Thomas Harris (1988), así como en otras producciones cinematográficas y literarias, ha contribuido a la creación de mitos y estereotipos que han distorsionado la percepción pública sobre la naturaleza de estos delitos (Yaksic, 2022).

Este entrelazamiento entre la realidad criminológica y la ficción ha creado barreras significativas para el estudio serio y académico del asesinato en serie. El interés y la fascinación del público, alimentados por representaciones sensacionalistas y muchas veces inexactas, han desviado la atención de los aspectos más críticos y fundamentales del estudio de estos delitos.

En este contexto, es esencial reevaluar y repensar la forma en que abordamos el estudio del asesinato en serie. Esto implica adoptar enfoques de investigación más rigurosos y objetivos, que se alejan del sensacionalismo y buscan respuestas fundamentadas en la evidencia y el análisis crítico.

Finalmente, es crucial reconocer la responsabilidad tanto de los medios de comunicación como de la academia en la formación de la narrativa pública sobre el asesinato en serie.

Sin perjuicio de los avances en la investigación sobre asesinatos en serie, existen aún numerosos retos y obstáculos, especialmente relacionados con la integridad y precisión de los

datos. Se mencionan varias fuentes de imprecisión y error, incluyendo incompetencia, negligencia, manipulación de datos y decisiones relacionadas con la privacidad y la presentación de los informes.

A pesar de estos desafíos, se subraya la necesidad de continuar la investigación empírica en este campo, que ha estado dominado por estudios cualitativos. Se menciona el trabajo de Adjorlolo y Chan (2014), que identifica tres grupos de investigadores en el tema de asesinatos en serie: aquellos que evitan definir el término, aquellos que confían en definiciones existentes o se refieren a casos conocidos, y aquellos que proponen u operacionalizan el término según sus propios enfoques e intereses de investigación.

En resumen, este texto reconoce los desafíos en la investigación de homicidios en serie debido a problemas con los datos, pero subraya la importancia de seguir adelante con investigaciones empíricas y adaptar definiciones y enfoques para abordar mejor estos desafíos.

Es gracias a este planteamiento por lo que se nos ha abierto la posibilidad de redefinir el término perfil geográfico. El objetivo es evitar una simplificación excesiva de la riqueza teórica necesaria para construir modelos explicativos. Por lo tanto, en esta tesis doctoral, se propone una aproximación al concepto del perfil geográfico, aproximación que resulta más estable conforme a las demandas de los modelos teóricos en los que se emplea.

Entendemos, por perfil geográfico, una metodología enfocada en la actividad espacial, temporal y cognitiva, orientada al estudio de la toma de decisiones de los delincuentes seriales, con el objetivo principal de identificar la zona más probable donde el delincuente pueda residir y estimar áreas de acción para futuros objetivos.

El componente fundamental en la aplicación del perfilado geográfico son los datos espaciales, que ofrecen una perspectiva del mundo real, aunque limitada. Según esta visión, la técnica empleada, ya sea avanzada o simple, no es tan crucial como el entendimiento que se deriva de ella. Existe una tendencia creciente en varias disciplinas, hacia la interpretación y comprensión del comportamiento de la información, en lugar de centrarse exclusivamente en las técnicas analíticas. Esto ha llevado a una perspectiva renovada donde el principal objetivo del análisis de datos no es simplemente generar resultados computacionales, sino interpretarlos de manera que proporcionen una mejor comprensión del entorno real.

En cuanto a los datos, se ha realizado una meticulosa selección de variables que podrían influir en el comportamiento de los delincuentes, enfocándose en elementos que estarían disponibles durante una investigación en curso. Esta selección ha priorizado la aplicabilidad práctica y la relevancia investigativa.

La profunda exploración y comprensión de estas variables y su impacto en el comportamiento delictivo han revelado *insights* valiosos. Estos conocimientos son cruciales para el desarrollo de estrategias de investigación y prevención más efectivas, lo que contribuye significativamente al progreso en los campos de la criminología y la seguridad pública. En conjunto, el estudio arroja luz sobre la importancia de la adecuada selección y operacionalización de variables y su papel en la comprensión y prevención del comportamiento delictivo.

Esta tesis se enfoca en explorar las oportunidades que brinda el uso de conocimientos científicos en la investigación criminal. A la vez, los resultados dan pie a futuras investigaciones. Hasta ahora, se ha estudiado principalmente el comportamiento de desplazamiento de los

delincuentes en función de la distancia recorrida, conocida como *journey to crime*, y las características asociadas a este.

La suposición generalizada de que la disminución de la distancia observada en datos agregados refleja una disminución similar en las actividades individuales de los delincuentes no es necesariamente correcta. Es posible que esta función de disminución de la distancia a nivel agregado se deba más a las diferencias en los patrones de actuación de distintos delincuentes.

En las estrategias de probabilidad de distancia, aunque se utilizan diversas funciones de decaimiento de la distancia y los detalles de los cálculos pueden variar, los resultados se ven más influenciados por el patrón espacial de los lugares donde se cometieron los delitos que por la función de decaimiento en sí mismo. La distribución de probabilidad resultante, basada en la función de decaimiento de la distancia, es más sensible al número de puntos incluidos en un cálculo que a la especificidad de la fórmula de decaimiento utilizada y a las variaciones en los parámetros de dichas funciones. Por lo tanto, diferentes funciones tienden a producir áreas de búsqueda similares. Factores como las distancias entre los escenarios del crimen, que definen el área de acción y búsqueda del delincuente, así como los valores atípicos y la cantidad de delitos en una serie específica, tienen un impacto más significativo en el perfil geográfico que las variaciones en las funciones de decaimiento de la distancia.

En este sentido, la conocida función de disminución de la distancia podría ser, en realidad, un producto metodológico no representativo. No obstante, aparte del trabajo de Canter et al. (2000), ha habido escasa reflexión sobre cómo distintas funciones impactan la operatividad de estos sistemas y determina cuál algoritmo matemático y conjunto de parámetros serían más apropiados para optimizar su rendimiento.

Actualmente, hay una falta de información detallada sobre los efectos de modificar los parámetros en las distintas funciones de decaimiento. Además, no se ha determinado cuál es la configuración óptima de estos parámetros para cada tipo de función de decaimiento y para las diversas tipologías de delitos.

En la investigación actual, se implementó un módulo en la herramienta GEO-SCRIPT diseñada para ajustar cada parámetro de la función, buscando minimizar la discrepancia entre el error del modelo y el valor real, según lo definido por el analista. Sin embargo, no se lograron resultados efectivos debido al elevado tiempo requerido para los cálculos de cada serie. Los lenguajes de programación utilizados no resultaron ser los más adecuados para esta tarea. Esto deja un espacio abierto para futuras investigaciones que se enfocan en la optimización de los parámetros y el ajuste del modelo

Las características y los factores relacionados con la dimensión espacial del perfilado geográfico han sido desarrollados y analizados detalladamente en esta tesis doctoral. Los resultados obtenidos se presentan en la parte III (Estudio Empírico II).

Los resultados presentados en el capítulo 8 indican que, aunque la formación en heurísticas puede mejorar moderadamente la habilidad para predecir las localizaciones de los puntos de anclaje de delincuentes en comparación con métodos actuariales, diversos factores, como las proporciones de delincuentes merodeadores y viajeros y el número de ubicaciones delictivas, pueden influir significativamente en los resultados.

Existen diversas razones para proceder con cautela al interpretar e integrar los resultados de este estudio en nuestra comprensión de la elaboración de perfiles geográficos. Una de estas razones es la posibilidad de que los resultados se vean afectados por las diferencias en los métodos

de medición utilizados para evaluar el desempeño de los grupos participantes y los procedimientos algorítmicos, así como la naturaleza limitada de las instrucciones proporcionadas a los participantes.

Además, es crucial considerar la selección de los datos y la medida de precisión utilizada en el estudio. La selección de datos no aleatoria y la utilización exclusiva de una tipología delictiva podrían haber influido en los resultados, mientras que la medida de precisión basada en la distancia de error puede no ser completamente representativa de la efectividad del método actuarial.

Por otro lado, es esencial abordar la posibilidad de que existan otras heurísticas más eficaces y que ciertos participantes, como el personal de la policía, podrían estar mejor preparados para implementar heurísticas de elaboración de perfiles. Del mismo modo, sería provechoso en investigaciones futuras proporcionar un conjunto más amplio de instrucciones a los participantes y realizar experimentos en escuelas de formación para las fuerzas de seguridad.

Dado el contexto de estas consideraciones, la interpretación de los resultados del estudio debe realizarse con prudencia hasta que se realicen investigaciones más profundas que comparen a delincuentes seriales viajeros y merodeadores.

Al considerar la totalidad de los resultados obtenidos, se evidencia un respaldo parcial a la primera hipótesis formulada en esta tesis doctoral; “Los sistemas de software basados en estos algoritmos matemáticos ofrecen una mayor precisión que las predicciones realizadas por expertos humanos mediante un enfoque clínico”.

Resulta esencial reconocer que la composición específica de las series delictivas empleadas en el estudio podría haber impactado en la precisión de los algoritmos. Este hecho

destaca la necesidad imperante de llevar a cabo investigaciones futuras que se enfoquen más detalladamente estos factores y continúen investigando el potencial de las heurísticas en el desarrollo del perfilado geográfico.

El objetivo del capítulo 9 es analizar tres estrategias de distribución de dispersión para construir un modelo de perfil geográfico basado en la teoría de conjuntos, que pueda determinar el mejor desempeño del modelo y medir su efectividad teórica y operativa en los cuerpos de seguridad (Salafranca y Yaksic, 2022).

En términos prácticos, la precisión de la medición de error de perfil se ha equilibrado con el tamaño del área promedio del perfil superior, en relación con las áreas totales de los modelos circulares y elípticos. Específicamente, a medida que el área del perfil superior aumenta, la medida del error de distancia del perfil disminuye, pero se vuelve menos útil para reducir el área del dominio del delito durante una investigación. Aunque estas áreas de búsqueda no son tan grandes como las derivadas de la hipótesis del círculo (Canter y Larkin, 1993), se han reducido lo suficiente para permitir que los cuerpos de seguridad inicien una búsqueda. Las áreas del perfil superior se han minimizado incorporando en los modelos de estrategia de dispersión y la superposición máxima de las geometrías resultantes. El modelo del diagrama de Venn ha mejorado significativamente al minimizar las áreas de búsqueda asociadas con la estimación del hogar de un SHO merodeador. Sin embargo, hay algunas desventajas en el método del diagrama de Venn, especialmente en las series donde no todos los círculos se superponen (Bots, 2010; Peter J. van Koppen et al., 2002) o en áreas repetidas con máxima superposición. Siguiendo la línea de trabajo

de Canter et al. (2013) en ambas desventajas, se ha utilizado el área más pequeña para definir el área de máxima superposición.

Un hallazgo principal del estudio es que el modelo elíptico tuvo un mejor desempeño que los modelos circulares, con una coincidencia del perfil del 44.04% con el área de búsqueda. La investigación demuestra que la mayor área de orientación de los modelos elípticos que representan una desviación estándar de la distancia desde el centro de la media coincide geoméricamente más precisamente con la dirección y forma de los patrones de la escena del delito. En el caso de los merodeadores, no se encontraron diferencias significativas en las distancias del modelo elíptico y el modelo circular de distancia variable del Gang. Tampoco se encontraron diferencias significativas en la evaluación del área de búsqueda del perfil en los modelos circulares. Estos hallazgos señalan importantes diferencias entre los modelos delincuentes y en la elección del modelo de perfil. Aunque los modelos elípticos pueden ser los más precisos en términos de error de distancia del perfil, pueden ser prácticamente menos útiles que el modelo circular del Gang, ya que tiene un área promedio del perfil superior mucho menor y solo una medición de error de distancia del perfil ligeramente menos preciso. La precisión del método contra los viajeros fue pobre, lo que está en línea con las conclusiones de Levine basadas en su prueba de validez para criminales que no viven en el centro de su distribución (Levine 2014).

Los resultados del presente estudio están en línea con muchos de los estudios de viaje al crimen que han demostrado que diferentes tipos de delincuentes difieren en las distancias que viajan (Canter y Gregory, 1994; Canter y Hammond, 2006; Capone y Woodrow W. Nichols, 1976; Hammond y Youngs, 2011).

Estos hallazgos apoyan a la segunda hipótesis planteada en esta investigación;” Mediante el análisis de las estrategias de distribución de dispersión y la construcción de un modelo de perfil geográfico basado en la teoría de conjuntos, podremos determinar con mayor precisión un área de referencia desde la cual iniciar la búsqueda del punto de anclaje de un SHO”

Desde el punto de vista de la investigación académica, el presente estudio aporta una visión y una metodología de trabajo para profundizar en la comprensión de los patrones de movilidad de los SHO y también es extrapolable a otras tipologías criminales.

En resumen, los principios de disminución de la distancia, zonas libres de delincuencia y dirección de viaje no parecen agregar valor a los resultados de la elaboración de perfiles geográficos de delincuentes. En esencia, la técnica más simple para determinar el perfil geográfico de un SHO (es decir, la técnica del círculo) es tan efectiva como las técnicas más complejas (Lopez, 2006). El uso de estrategias más simples es consistente con varios estudios, como el de Snook (2000), en el que estudiantes sin conocimiento previo del perfil geográfico de los delincuentes fueron capaces de emitir juicios basados en dos reglas de decisión tan precisas como los resultados usando la probabilidad. estrategias de distribución. Esto no significa que deban descartarse a priori enfoques que utilizan técnicas más complicadas. La eficacia de la elaboración de perfiles geográficos de los SHO no está determinada únicamente por la técnica elegida, sino principalmente por la forma en que la técnica es aplicada por los perfiladores geográficos y dentro de los cuerpos de seguridad. En este sentido, cuanto mejor sea la coordinación del perfil geográfico de los SHO con otras formas de información y/o métodos de detección de delincuentes, mayor será su utilidad práctica.

En el análisis de datos criminológicos, es común encontrar variables espaciales con valores atípicos (outliers), que se caracterizan por desviarse significativamente de la mayoría de los valores y no encajar en el patrón general de distribución de la variable. Diversos autores han ofrecido distintas definiciones para estos valores atípicos y han propuesto variadas metodologías para identificarlos y tratarlos adecuadamente. En la literatura científica existe un debate considerable respecto a la eliminación de los valores atípicos. Se argumenta que es crucial entender la causa de estos valores atípicos y la influencia que pueden ejercer en los resultados de los análisis antes de decidir si se deben eliminar o mantener. Esto se debe a que su presencia o ausencia puede alterar significativamente las conclusiones derivadas del análisis, y en algunos casos, su eliminación podría resultar en la pérdida de información relevante.

La metodología propuesta por Newton y Swoope, detallada en los capítulos 10 y 11, se basa en la estadística descriptiva y se enfoca especialmente en el concepto del centro medio. Aunque este enfoque es relevante, es susceptible a los valores espaciales atípicos, lo cual podría limitar su eficacia en aplicaciones prácticas. Para mejorar y aumentar su precisión, proponemos una modificación de la ecuación original mediante la incorporación del algoritmo de Weiszfeld, el cual es conocido por su capacidad de manejar eficientemente dichas anomalías. La simplicidad y facilidad de implementación de este algoritmo lo convierte en una opción atractiva para estrategias de perfilado geográfico de bajo costo, brindando una alternativa viable para entidades que buscan más accesibles. En primer lugar, en términos de precisión general, podríamos considerar la estrategia del modelo del centro de distancia mínima como "buena", en comparación con el modelo tradicional de Newton-Swoope.

Basándonos en los supuestos propuestos por Newton y en relación con el primer supuesto ha revelado que el modelo del centro de distancia mínima muestra un desempeño superior, especialmente al estimar la proximidad del domicilio del delincuente a partir del quinto incidente.

Los resultados confirman investigaciones previas (Levine, 2005; Paulsen, 2006; Snook, 2005), que indican que el centro de distancia mínima suele ser una medida más acertada de la tendencia central en una distribución delictiva.

Sin embargo, el segundo supuesto, que considera la ubicación del punto de anclaje real dentro del área del perfil superior, tuvo un éxito limitado. Solo en 4 de los 11 perfiles estudiados usando el modelo del centro de distancia mínima, el punto de anclaje real cayó dentro del área del perfil superior. En contraste, el modelo de centro medio no logró situar ningún punto de anclaje dentro de esta área, lo que indica que no es una condición confiable para determinar el perfil superior como parámetro de área de riesgo.

El tercer supuesto, que postula que el área de búsqueda debería reducirse con cada delito sucesivo después del cuarto o quinto incidente, no cumplió con las expectativas en cuatro de las once series criminales estudiadas (36,3%), mostrando un rendimiento inferior al esperado. en el 63,7% de los casos.

Al considerar la totalidad de los resultados obtenidos, se evidencia un respaldo parcial a la tercera hipótesis formulada en esta tesis doctoral; “Basándonos en los supuestos propuestos por Newton (1988) y utilizando el algoritmo de Weiszfeld, observaremos mejoras en los valores atípicos en las tres condiciones de la metodología propuesta”.

No existen teorías geográficas que expliquen directamente la distribución espacial del delito. Sin embargo, se ha establecido un enlace entre la Geografía humana y la Criminología,

gracias al desarrollo de un fuerte paralelismo entre ambas disciplinas. En este marco, no se tiene conocimiento de investigaciones que hayan validado la eficacia de la variable de distancia en modelos probabilísticos de perfilado geográfico. Un aspecto crucial para los algoritmos de perfilado geográfico es la elección de la métrica adecuada para medir la distancia, teniendo en cuenta que su adaptabilidad y comportamiento en el entorno son fundamentales para superar los desafíos que este plantea.

En el desarrollo de las investigaciones sobre las conductas de movilidad ha sido comúnmente asumido el cálculo de la distancia en línea recta o euclidiana entre el lugar del domicilio del delincuente y la escena del delito, como indicador de la distancia recorrida. Esto significa que los modelos de perfilado probabilísticos actuales asumen una superficie isotrópica, donde los obstáculos son uniformes en todas las direcciones. Como consecuencia, estos modelos no se adaptan a las variaciones inherentes exhibidas por una red de transporte particular, como la ruta, dirección, velocidad, características del paisaje, desarrollo urbanístico, límites, etc. Son muy pocos los que incluyen en sus análisis de perfilado geográfico a los actores geográficos (distancias funcionales) como una variable que influya en el comportamiento espacial del delincuente.

A raíz de estos planteamientos surge la necesidad de explorar un área asimétrica del entorno urbano y comprobar si las características del paisaje pueden aumentar significativamente la exactitud del perfil geográfico.

En esta investigación, se concluye que no es necesario añadir medidas de distancia funcional en los modelos de perfilado geográfico probabilístico. Estos resultados apoyan la investigación de Canter (2003), que indica que la ruta de viaje real del delincuente no determina su "espacio de conciencia". En cambio, el comportamiento delictivo se basa en el mapa mental del

individuo y su percepción selectiva de las características físicas del entorno. Por lo tanto, los delincuentes suelen percibir el camino entre dos puntos como una línea recta. Esta perspectiva se refleja en gran parte de las investigaciones sobre desplazamientos criminales, que utilizan esta medida de distancia. La distancia en línea recta entre la residencia del sospechoso y la escena del crimen se justifica con el argumento de que, aunque se desconozca la ruta exacta tomada por el autor del crimen, dicha distancia ofrece una estimación razonable del alcance de su movilidad. Por lo tanto, no podemos confirmar la quinta hipótesis; “La precisión del perfil geográfico en estrategias de distancia de probabilidad podría mejorarse integrando la anisotropía espacial”.

Sin embargo, como señalaron Capone y Nichols (1976), parece lógico suponer que las diferentes funciones podrían proporcionar los mejores ajustes a distribuciones de distancia para diferentes tipos de delitos, y la investigación futura necesitaría determinar si éste es de hecho, el caso.

Este estudio sugiere que una mejora en la precisión de los datos y la implementación de modelos más elaborados que consideran diversos factores como los procesos cognitivos del delincuente, el esfuerzo requerido para desplazarse, y las oportunidades y atractivo del objetivo podrían ser cruciales para entender de manera más completa los desplazamientos de los delincuentes en relación con el acto delictivo.

Finalmente, se subraya que la distinción entre delincuentes merodeadores y viajeros es más determinante para decidir si un delincuente puede ser objeto de un perfil geográfico que el cumplimiento o no de un patrón de decaimiento de distancia. El reconocimiento de estas distinciones y complejidades es fundamental para avanzar en el campo del perfil geográfico y para

desarrollar métodos más precisos y adaptativos que puedan responder a la naturaleza multifacética del comportamiento delictivo.

En este estudio, se examinaron dos modelos de aprendizaje automático supervisado para definir patrones espaciales en crímenes. Los modelos se centraron en discernir entre dos tipos de perfiles delictivos: merodeadores y viajeros.

Al comparar los resultados con investigaciones anteriores, se encontraron algunas discrepancias en relación con las variables que son determinantes en la previsibilidad. Mientras algunos estudios resaltan la importancia de la concentración de los lugares de delito, otros consideran la distancia entre delitos o la distancia de la serie de delitos.

A pesar de los avances, es esencial considerar que la predicción basada en la perfilación geográfica no es infalible. La eficacia del modelo puede variar dependiendo del tipo de delito y las características del entorno. Además, mientras algunas variables mostraron ser relevantes en la predicción, otras no lo fueron, lo que sugiere la posibilidad de variación en diferentes muestras.

En el aprendizaje automático, la calidad y cantidad del conjunto de datos de entrenamiento es esencial, ya que el entrenamiento de un modelo implica ajustar sus hiperparámetros. Aunque las redes neuronales ofrecen beneficios predictivos, a menudo se les critica por ser "cajas negras", complicando la interpretación de sus resultados (Paruelo y Tomasel, 1997).

Un hallazgo importante en el estudio ha sido el impacto de la estandarización de datos en el rendimiento del modelo. Esta recalibración de las características es crucial, especialmente para algoritmos sensibles a las magnitudes de entrada. La estandarización mejora la precisión y sensibilidad, evitando el sobreajuste y ampliando la generalización del modelo. El modelo en

capas, debido a su arquitectura compleja, ha mostrado una adaptabilidad y rendimiento superior en presencia de datos estandarizados.

Las métricas de rendimiento utilizadas revelaron diferencias en la eficacia de los modelos al predecir clases, propensión al error y concordancia con valores reales. El modelo en capas superó generalmente al modelo simple, pero hubo excepciones, como en la condición del (*Rango convex hull*) RCH con estandarización, indicando la posible necesidad de considerar aspectos contextuales de los datos.

Los resultados hallados utilizando técnicas de aprendizaje automático supervisado, se puede obtener una efectividad en la clasificación utilizando un modelo de regresión logística en un 75.4% en (*Range Criminal Circle*) RCC y un 71.5% en (*Rango convex hull*) RCH y utilizando un modelo de redes neuronales en un 95.7% en RCC y un 80.8% en RCH.

Estos datos confirman la cuarta hipótesis planteada; “Mediante el uso de técnicas de aprendizaje automático supervisado, es posible clasificar a los SHOs como merodeadores o viajeros con la información obtenida durante sus series criminales, y que esta clasificación puede facilitar y mejorar la precisión en la selección o priorización al realizar un perfil geográfico”.

En conclusión, la perfilación geográfica, a través del aprendizaje automático, puede ofrecer valiosas perspectivas en Criminología, pero su uso debe hacerse con precaución, considerando sus limitaciones y la necesidad de ajustar los modelos según el contexto del delito.

Este estudio se ha enfocado en probar la hipótesis de consistencia de direccionalidad para los datos del movimiento desde el domicilio de los SHOs a la víctima. A través de los resultados, se ha identificado que los delincuentes viajeros, SHOs, muestran una consistencia direccional en un 70% de los casos. Este hallazgo es crucial para la clasificación previa del tipo de delinciente

antes de realizar un perfil geográfico, ya que los softwares actuales presentan limitaciones para perfilar con precisión las series de viajeros.

Los resultados hallados permiten aceptar la sexta hipótesis de esta tesis doctoral; “*Hipotetizamos que los asesinos seriales pueden ser categorizados como merodeadores o viajeros medidos en la consistencia direccional observada durante sus series criminales*”.

En resumen, el estudio proporciona avances significativos en la comprensión de la coherencia direccional de los SHOs y en la identificación de delincuentes viajeros al inicio de una investigación. Sin embargo, este enfoque también revela varias limitaciones y desafíos que deben ser abordados en investigaciones futuras para incrementar la precisión y confiabilidad en la clasificación y el perfilado geográfico de delincuentes. Una de estas limitaciones es que los métodos basados en modelos para analizar la orientación circular se aplican raramente en el perfilado geográfico. Esto se debe, en parte, a que su implementación no es sencilla en el software estadístico convencional.

Contrariamente a lo que a menudo presuponen los críticos de las metodologías cuantitativas, la ciencia contemporánea no solo admite la presencia del azar a nivel individual, sino que también reconoce patrones probabilísticos a nivel colectivo. Es por ello por lo que la "Nueva Geografía" está evolucionando desde modelos puramente deterministas hacia enfoques estocásticos, donde se contempla el carácter aleatorio y donde la probabilidad juega un rol importante. Como bien señala Capel en la introducción de "Excepcionalismo en Geografía" de Schaefer (1988), esta transición es un reflejo de la adaptabilidad y avance de la disciplina geográfica (Celemín, 2020).

Existen nuevos enfoques que aspiran a ahondar aún más en el ámbito de la perfilación geográfica, Wang (2012) resaltó la importancia de la sinergia entre diversas disciplinas académicas como la criminología, geografía, informática y estadística, así como la colaboración con empresas y expertos del sector. Esta interacción multidisciplinaria tiene que permitir que las aplicaciones de SIG evolucionen desde la simple representación cartográfica de crímenes hasta el desarrollo de análisis espaciales especializados e integración en modelos predictivos avanzados.

La era actual, marcada por una revolución en la inteligencia computacional y el acceso a grandes volúmenes de datos, ha impulsado significativamente la investigación en homicidios en serie hacia modelos predictivos más favorables y a una comprensión más profunda de estos fenómenos. Los investigadores están diseñando modelos que no solo identifican a potenciales futuros autores de homicidios en serie, sino que también decodifican patrones delictivos. Esto se traduce en herramientas cruciales para anticipar y prevenir comportamientos delictivos.

La implementación de este tipo de técnicas avanzadas busca mejorar la precisión y efectividad de la perfilación geográfica, lo que resulta esencial para la prevención y resolución de delitos en serie.

En el ámbito del perfilado geográfico, existen dos dimensiones que no se han explorado en esta tesis doctoral, pero que representan oportunidades interesantes para futuras investigaciones. Por un lado, está la dimensión temporal, a la que se ha prestado poca atención en los modelos de perfil geográfico. Esta dimensión se enfoca en la intermitencia en la delincuencia, definida como los intervalos de tiempo entre crímenes o los períodos de enfriamiento. Por otro lado, está la dimensión cognitiva, que permite la reconstrucción e interpretación del mapa mental del delincuente, destacando su naturaleza subjetiva.

Para comprender cómo los delincuentes toman decisiones y qué factores influyen en ellas, se requiere más investigación, especialmente para entender la formación de patrones espaciales en las escenas de los delitos. El método propuesto por Maldonado y Salafranca (2019), se acerca más a la aplicación del componente subjetivo del perfil geográfico, ofreciendo una alternativa al uso exclusivo de funciones de decaimiento con la distancia. Esto se debe a que se han considerado elementos potenciales que pueden estar formando parte del mapa mental del criminal, para la estimación de las áreas de actuación futura. En otras palabras, el método presentado toma en cuenta las variables ambientales que podrían estar guiando el comportamiento espacial del delincuente.

En conclusión, esta tesis ha explorado en profundidad la dimensión espacial del perfilado geográfico. A través de un análisis detallado y riguroso, se ha demostrado las debilidades y las oportunidades del perfilado geográfico. Se espera que los hallazgos aquí presentados inspiren y motiven a otros investigadores a continuar explorando este fascinante ámbito de estudio.

REFERENCIAS BIBLIOGRÁFICAS

- Aamodt, M., Fox, J. A., Hickey, E., Hinch, R., Labuschagne, G., Levin, J., McClellan, J., Nelson, B., Newton, M., Quinet, K., Steiger, C., White, J., & Yaksic, E. (2020). *Consolidated Serial Homicide Offender Database*. Harvard Dataverse, V1 .
https://dataverse.harvard.edu/dataverse/serial_homicide
- Aamodt, M. G., Leary, T., & Southard, L. (2020). *Radford / FGCU annual report on serial killer statistics : 2020*. Radford University. <https://doi.org/10.13140/RG.2.2.33405.38884>
- Aamodt, M., & Moyse, C. (2003). Researching the multiple murderer: A comprehensive bibliography of books on specific serial, mass, and spree killers. *Journal of Police and Criminal Psychology, 18*(1), 61–85. <https://doi.org/10.1007/BF02802609>
- Adjorlolo, H.C., & Chan, H. C. O. (2014). The controversy of defining serial murder: Revisited. *Aggression and Violent Behavior, 19*(5), 486–491. <https://doi.org/10.1016/j.avb.2014.07.003>
- Ainsworth, P. B. (2001). *Offender profiling and crime analysis*. Portland: Willan Publishing.
- Alison, L., Smith, M. D., & Morgan, K. (2003). Interpreting the accuracy of offender profilers. *Psychology, Crime & Law, 9*(2), 185–195. <https://doi.org/10.1080/1068316031000116274>
- Allely, C. S., Minnis, H., Thompson, L., Wilson, P., & Gillberg, C. (2014). Neurodevelopmental and psychosocial risk factors in serial killers and mass murderers. *Aggression and Violent Behavior, 19*(3), 288–301. <https://doi.org/10.1016/j.avb.2014.04.004>

- Alonso Sarria, F., Gomariz Castillo, F., & Cánovas García, F. (2012). Conocimiento abierto en sistemas de información geográfica. Una estrategia para la geografía física. *Nimbus: Revista de Climatología, Meteorología y Paisaje*, 29, 21–34.
- Alston, J. D. (1994). The serial rapist's spatial pattern of target selection. [Tesis de maestría, Simon Fraser University]. In *Brigham Young University*. <https://summit.sfu.ca/item/5080>
- Anselin, L. (2001). Spatial Econometrics. In *A Companion to Theoretical Econometrics* (Badi H. Ba). Blackwell Publishing Ltd.
- Apostol, T. M. (1967). *Calculus*. John Wiley.
- Arenas, R. C. (2013). *Uso de ArcGIS y Crime Analyst para Seguridad y Justicia*. [Sesión de conferencia] Conferencia Latinoamericana de Usuarios Esri LAUC 2013, Lima, Perú.: Recuperado de: <http://es.slideshare.net/telematicaperu/uso-dearcgis-y-crime-analyst-para-seguridad-y-justicia-claudia-lorena-rengifo-arenas-fiscalageneral-de-la-nacin-colombia>
<http://es.slideshare.net/telematicaperu/uso-de-arcgis-y-crime-analyst-para-seguridad-y-justicia-claudia-lorena-rengifo-arenas-fiscalageneral-de-la-nacin-colombia>
- Bailey, T. C., & Gatrell, A. C. (1995). Interactive Spatial Data Analysis. *Longman Scientific & Technical*, 413.
- Bair Analytics Inc. (2014). *ATAC Automated Tactical Analysis of Crime* (2014.9) [Software]. <https://risk.lexisnexis.com/>
- Baldwin, J., & Bottoms, A. E. (1976). The Urban Criminal: A Study in Sheffield. In *Tavistock*

Publications.

Barnes, N. (2010). Publish your computer code: it is good enough. *Nature*, 467(7317), 753.

<https://doi.org/10.1038/467753a>

Batschelet, Edward, 1914-1979. (1981). *Circular statistics in biology / Edward Batschelet*.

London: Academic press.

Beauregard, E., & Martineau, M. (2016). *The sexual murderer: Offender behaviour and*

implications for practice (1st ed.). Routledge. <https://doi.org/10.4324/9781315683768>

Beijsterveldt, K. van. (2006). *Reiziger of stroper? Geografische daderprofilering en*

reispatronen van daders van vermogensdelicten. [Tesis de maestría no publicada]

Rotterdam: Erasmus Universiteit.

Benjamini, Y., & Hochberg, Y. (1995). Controlling the False Discovery Rate: A Practical and

Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society. Series B*

(Methodological), 57(1), 289–300. <http://www.jstor.org/stable/2346101>

Bennell, C., Emeno, K., Snook, B., Taylor, P., & Goodwill, A. (2009). The precision, accuracy

and efficiency of geographic profiling predictions: a simple heuristic versus mathematical

algorithms. *Crime Mapping: A Journal of Research and Practice*, 1(2), 65–84.

<http://eprints.lancs.ac.uk/49927/>

Bennell, C., Taylor, P. J., & Snook, B. (2007). Clinical versus Actuarial Geographic Profiling

Strategies: A Review of the Research. *Police Practice and Research*, 8(4), 335–345.

<https://doi.org/10.1080/15614260701615037>

Bernasco, W. (2007). The usefulness of measuring spatial opportunity structures for tracking down offenders: A theoretical analysis of geographic offender profiling using simulation studies. *Psychology, Crime and Law*, 13(2), 155–171.

<https://doi.org/10.1080/10683160600558402>

Bernasco, W. (2010). A Sentimental journey to crime: Effects of residential history on crime location. *Criminology*, 48(2), 389–416. <https://doi.org/https://doi.org/10.1111/j.1745-9125.2010.00190.x>

Bernasco, W. (2014). Crime Journeys: Patterns of Offender Mobility. In M. Tonry (Ed.), *Oxford Handbooks Online in Criminology and Criminal Justice*. Oxford University Press.

<https://doi.org/10.1093/oxfordhb/9780199935383.013.49>

Berrie, E. A., & Morrison, B. (2013). *A Developmental Model of Serial Killers : A Retrospective Analysis* [Tesis de maestría, Simon Fraser University]. <https://summit.sfu.ca/item/13774>

Biessels, J. E. (2017). *Een geografisch distance decay- portret*. [Tesis de maestría no publicada] Vrije Universiteit Amsterdam.

Bijleveld, C., & Commandeur, J. J. F. (2012). *Multivariate analyse : een inleiding voor criminologen en andere sociale wetenschappers*. (3e gewijzi). Den Haag: Boom Juridische uitgevers. <https://lib.ugent.be/catalog/rug01:002066963>

Block, R., & Bernasco, W. (2009). Finding a serial burglar's home using distance decay and

- conditional origin-destination patterns: A test of empirical Bayes journey-to-crime estimation in the Hague. *Journal of Investigative Psychology and Offender Profiling*, 6(3), 187–211. <https://doi.org/10.1002/jip.108>
- Bohm, R. M. (1986). Crime, criminal and crime control policy myths. *Justice Quarterly*, 3(2):193-214.
- Bolle, E. A. W., Göbel, F., & Lenoir, J. M. H. (1973). *Beschrijvende statistiek*. Deventer: Kluwer.
- Boots, B. N., & Getis, A. (1988). *Point Pattern Analysis*. Reprint. Edited by Grant Ian Thrall. WVU Research Repository, 2020. <https://books.google.es/books?id=vkK3AAAACAAJ>
- Bots, K. (2010). *De Prestaties van de Cirkelmethode van Van Koppen, De Poot en Van Koppen (Vergelijking met twee technieken van Geografische Daderprofilering)*. [Tesis de maestría no publicada] Vrije Universiteit te Amsterdam.
- Brantingham, P. J., & Brantingham, P. L. (1981). *Environmental criminology*. Sage Publications
- Brantingham, P. J., & Brantingham, P. L. (1984). *Patterns in crime*. Macmillan Publishing Company.
- Brantingham, P. L., & Brantingham, P. J. (1993). Nodes, paths and edges: Considerations on the complexity of crime and the physical environment. *Journal of Environmental Psychology*, 13(1), 3–28. [https://doi.org/10.1016/S0272-4944\(05\)80212-9](https://doi.org/10.1016/S0272-4944(05)80212-9)
- Brantingham, P. L., & Brantingham, P. J. (1995). Criminality of place: Crime generators and

- crime attractors. *European Journal on Criminal Policy and Research*, 3(3), 5–26.
<https://doi.org/10.1007/BF02242925>
- Brown, L. A., & Moore, E. G. (1970). The Intra-Urban Migration Process: a Perspective. *Geografiska Annaler: Series B, Human Geography*, 52(1), 1–13.
<https://doi.org/10.1080/04353684.1970.11879340>
- Brunsdon, C., & Corcoran, J. (2006). Using circular statistics to analyse time patterns in crime incidence. *Computers, Environment and Urban Systems*, 30(3), 300–319.
<https://doi.org/https://doi.org/10.1016/j.compenvurbsys.2005.11.001>
- Bun, M., Li, J., & Zemke, I. (2010). *Tracking Serial Criminals with a Road Metric*. 1–19.
<http://www.math.washington.edu/~morrow/mcm/mcm.html>
- Burke L, & Ignizio JP. (1997). A Practical Overview of Neural Networks. *Journal of Intelligent Manufacturing*, 8, 157–165. <https://doi.org/doi:10.1023/a:1018513006083>.
- Busch, K. A., & Cavanaugh, J. L. (1986). The Study of Multiple Murder: Preliminary Examination of the Interface Between Epistemology and Methodology. *Journal of Interpersonal Violence*, 1(1), 5–23. <https://doi.org/10.1177/088626086001001002>
- Butkovic, A. (2019). *GeoCrime* (Versión 1.1) [Software]. <http://github.com/ericnewton76/gmaps-api-net>
- Butkovic, A., Mrdovic, S., Uludag, S., & Tanovic, A. (2019). Geographic profiling for serial cybercrime investigation. *Digital Investigation*, 28, 176–182.

<https://doi.org/10.1016/j.diin.2018.12.001>

Buzai, G., & Baxendale, C. (2015). Análisis socioespacial con sistemas de información geográfica marco conceptual basado en la teoría de la geografía, *Ciencias Espaciales* 8(2): 391–408. <https://doi.org/10.5377/ce.v8i2.2089>

Câmara, G., Vinhas, L., & de Souza, R. C. M. (2012). Free and open source GIS: Will there ever be a Geo-Linux? *Lecture Notes in Geoinformation and Cartography*, 0, 229–245. https://doi.org/10.1007/978-3-642-10595-1_14

Canter, D. (1995). *Dragnet* (Versión Dragnetk) [Software] <https://www.davidcanter.com/professional-services/software/>

Canter, D. (2004). Geographical profiling of criminals. *Medico-Legal Journal*, 72(2), 53–66. <https://doi.org/10.1258/rsmlj.72.2.53>

Canter, D. (2005). Confusing operational predicaments and cognitive explorations: comments on Rossmo and Snook et al. *Applied Cognitive Psychology*, 19(5), 663–668. <https://doi.org/https://doi.org/10.1002/acp.1143>

Canter, D. (2011). Resolving the offender “profiling equations” and the emergence of an investigative psychology. *Current Directions in Psychological Science*, 20(1), 5–10. <https://doi.org/10.1177/0963721410396825>

Canter, D., Coffey, T., Huntley, M., & Missen, C. (2000). Predicting serial killers’ home base using a decision support system. *Journal of Quantitative Criminology*, 16(4), 457–478.

<https://doi.org/10.1023/A:1007551316253>

- Canter, D., & Gregory, A. (1994). Identifying the residential location of rapists. *Journal of the Forensic Science Society*, 34(3), 169–175. [https://doi.org/10.1016/S0015-7368\(94\)72910-8](https://doi.org/10.1016/S0015-7368(94)72910-8)
- Canter, D., & Hammond, L. (2006). A comparison of the efficacy of different decay functions in geographical profiling for a sample of US serial killers. *Journal of Investigative Psychology and Offender Profiling*, 3(2), 91–103. <https://doi.org/10.1002/jip.45>
- Canter, D., & Hammond, L. (2007). Prioritizing Burglars: Comparing the Effectiveness of Geographical Profiling Methods. *Police Practice and Research*, 8(4), 371–384. <https://doi.org/10.1080/15614260701615086>
- Canter, D., & Larkin, P. (1993). The environmental range of serial rapists. *Journal of Environmental Psychology*, 13(1), 63–69. [https://doi.org/10.1016/S0272-4944\(05\)80215-4](https://doi.org/10.1016/S0272-4944(05)80215-4)
- Capone, D. L., & Woodrow W. Nichols, J. (1976). Urban Structure and Criminal Mobility. *American Behavioral Scientist*, 20(2), 199–213. <https://doi.org/10.1177/000276427602000203>
- Carlstein, T., Parkes, D., & Thrift, N. J. (1978). *Human activity and time geography*. J. Wiley.
- Celemín, J. P. (2020). Cincuenta Años De La Primera Ley De Tobler: Revisión De Sus Aportes Teóricos Y Prácticos a La Ciencia Geográfica. *Luján, Año*, 12, 1–18. <http://www.revistageosig.wixsite.com/>
- Cordozo, O.D., & Silva, D. (2015). *Funciones distance decay y Sistemas de Información*

Geográfica (SIG) para la estimación de demanda potencial en el Transporte Público de Resistencia (Cahco, Argentina). Revista Transporte Y Territorio, (13,) 80–99.

<https://doi.org/10.34096/rtt.i13.1878>

Chainey, S. (2019). *Technical note Introducing geographic profiling crime analysis in Mexico : principles of geographic profiling , examples of its use , training and challenges in its implementation.* <https://www.ucl.ac.uk/security-crime-science/>

Chainey, S., & Ratcliffe, J. (2005). Spatial Theories of Crime. In *GIS and Crime Mapping* (pp. 79–113). <https://doi.org/https://doi.org/10.1002/9781118685181.ch4>

Chainey, S., & Ratcliffe, J. (2013). GIS and Crime Mapping. In *GIS and Crime Mapping*. John Wiley & Sons. <https://doi.org/10.1002/9781118685181>

Chrysanthus, P. (1947). *Spinnen en hymenoptera aculeate*. Tijdschrift voor Entomologie.

Clarke, R. V. (2012). Opportunity makes the thief. Really? And so what? *Crime Science, 1*(1), 3. <https://doi.org/10.1186/2193-7680-1-3>

Clements, D. H., & Meredith, J. S. (1993). Research on Logo, effects and efficacy. *Journal of Computing in Childhood Education archive, 4*.

Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement, 20*, 37–46. <https://doi.org/10.1177/001316446002000104>

Cohen, L. E., & Felson, M. (1979). Social Change and Crime Rate Trends: A Routine Activity Approach. In *American Sociological Review 44* (4):558. <https://doi.org/10.2307/2094589>

Cornish, D. B., & Clarke, R. V. G. (1986). *The reasoning criminal : rational choice perspectives on offending* . Hague: Springer-Verlag.

<https://doi.org/https://doi.org/10.4324/9781315134482>

Cornish, D. B., & Clarke, R. V. G. (2016). The rational choice perspective. In R. Wortley & M. Townsley (Eds.), *Environmental Criminology and Crime Analysis* (2nd ed.). Routledge.

<https://doi.org/https://doi.org/10.4324/9781315709826>

Cruz Rot, M. (2006). Introducción al análisis de datos mapeados o algunas de las (muchas) cosas que puedo hacer si tengo coordenadas. *Ecosistemas* 15 (3): 19–39.

Curt R. Bartol, & Anne M. Bartol. (2013). *Criminal & Behavioral Profiling* (1st ed.). SAGE Publications, Inc.

Daele, V., & Bernasco, W. (2012). Exploring Directional Consistency in Offending: The Case of Residential Burglary in The Hague. *Journal of Investigative Psychology and Offender Profiling*, 9(2), 135–148. <https://doi.org/10.1002/jip.1358>

Daniell, C. (2008). Geographic profiling in an operational setting: the challenges and practical considerations, with reference to a series of sexual assaults in Bath, England. In L. T. Spencer Chainey (Ed.), *Crime Mapping Case Studies: Practice and Research* (1^a). John Wiley & Sons. <https://doi.org/10.1002/9780470987193.ch6>

De Luca, R., & Mastronardi, V. (2011). *I Serial Killer*. New Compton Editori.

De Luca, R. (2001). *Anatomia del serial killer 2000 : nuove prospettive di studio e intervento per*

un'analisi psico-socio-criminologica del l'omicidio seriale nel terzo millennio .Giuffrè Editore, Milano.

Deakin, R. E., Bird, S. C., & Grenfell, R. I. (2002). The centroid? Where would you like it to be? *Cartography*, *31*(2), 153–167. <https://doi.org/10.1080/00690805.2002.9714213>

Dempsey, C. (2016). (2023, Noviembre 19). *Commercial GIS Software Applications*. GIS LOUNGE. <https://www.gislounge.com/gis-software-applications/>

Denzin, N., & Lincoln, Y. S. (1994). *Handbook of Qualitative Research*. Sage Publications, Inc.

Dern, H., Frönd, R., Straub, U., Vick, J., & Witt, R. (2004). *Comportamiento geográfico de ofensores desconocidos en delitos de violencia sexual*. Oficina federal de Investigación criminal (BKA): Wiesbaden

Douglas, J. E., Ressler, R. K., Burgess, A. W., & Hartman, C. R. (1986). Criminal profiling from crime scene analysis. *Behavioral Sciences and The Law*, *4*(4), 401–421. <https://doi.org/10.1002/bsl.2370040405>

Durkheim, É. (1897). *Le suicide. Étude de sociologie*. Félix Alcan.

Ebdon, D. (1988). *Statistics in Geography*, 2nd Edition, Blackwell Publishing, Oxford .

Edelstein, A. (2015). Combining psychological and sociological theories for better understanding and explaining crime, a look into serial killing. *International Journal of Emergency Mental Health*, *17*(3), 628–629. <https://doi.org/10.4172/1522-4821.1000237>

- Edelstein, A. (2019). Cooling-Off Periods among Serial Killers. *Journal of Psychology & Behavior Research*, 2(1), p1. <https://doi.org/10.22158/jpbr.v2n1p1>
- Edwards, M. J. (2004). *Analysing Spatial Patterns of Convicted Serial Arsonists*. [Tesis de maestría, University of Canterbury]. <https://canterbury.libguides.com/rights/theses>
- Eldridge, D., & Jones, P. (1991). Warped Space: a geography of distance decay. *Association of American Geographers*, 43(4), 500–511.
- Emeno, K., Bennell, C., Snook, B., & Taylor, P. J. (2016). Geographic profiling survey: A preliminary examination of geographic profilers views and experiences. *International Journal of Police Science & Management*, 18(1), 3–12.
<https://doi.org/10.1177/1461355715621070>
- English, W. J. (2008a). *Geoprofile: Developing and establishing the reliability of a new geographic profiling software system*. [Tesis de maestría, The Chicago School of Professional Psychology].
- English, W. J. (2008b). *GeoProfile* (Versión 1.1) [Software] Software sin acceso.
- Entman, R. M. (1989). How the media affect what people think: An information processing approach. *The Journal of Politics*, 51, 347–370. <https://doi.org/10.2307/2131346>
- Estebanez Álvarez, J. (1987). La imagen de la geografía cuantitativa elaborada por sus oponentes. *Anales de Geografía de La Universidad Complutense de Madrid*, 7, 57.
- Farrell, A. L., Keppel, R. D., & Titterington, V. B. (2013). Testing existing classifications of

- serial murder considering gender: An exploratory analysis of solo female serial murderers. *Journal of Investigative Psychology and Offender Profiling*, 10(3), 268–288.
<https://doi.org/10.1002/jip.1392>
- Felson, M., & Clarke, R. (1998). La ocasión hace al ladrón. Teoría práctica para la prevención del delito. In *Series Claves del Gobierno Local* (Issue 6). Fundación Democracia y Gobierno Local. <http://repositorio.gobiernolocal.es/xmlui/handle/10873/855>
- Ferguson, B. (1987). *Homicide Investigation Tracking System (HITS)*. Recuperado de <https://www.atg.wa.gov/hits-overview>
- Field, B., & MacGregor, B. (1987). *Forecasting Techniques for Urban and Regional Planning*. UCL Press, Ltd.
- Forno, A. D., & Merlone, U. (2013). Chaotic Dynamics in Organization Theory. In G. I. Bischi, C. Chiarella, & I. Sushko (Eds.), *Global Analysis of Dynamic Models in Economics and Finance: Essays in Honour of Laura Gardini* (pp. 185–204). Springer Berlin Heidelberg.
https://doi.org/10.1007/978-3-642-29503-4_8
- Fotheringham, S. (1980). Spatial structure, spatial interaction, and distance-decay parameters. *Annals of the Association of American Geographers*, October.
<https://macsphere.mcmaster.ca/handle/11375/11312>
- Fox, J. A., & Levin, J. (2001). *The will to kill: making sense of senseless murder*. Allyn and Bacon.

- Frank, R., Andresen, M. A., & Brantingham, P. L. (2013). Visualizing The directional bias in property crime incidents for five Canadian municipalities. *Canadian Geographer*, 57(1), 31–42. <https://doi.org/10.1111/j.1541-0064.2012.00450.x>
- Fridel, E. E., & Fox, J. A. (2018). *Too Few Victims : Finding the Optimal Minimum Victim Threshold for Defining Serial Murder*. 8(4), 505–514.
- Fritsch, S., Guenther, F., & Wright, M. N. (2019). *neuralnet: Training of Neural Networks* (R package version 1.44.2.). <https://cran.r-project.org/package=neuralnet>
- Gaile, G. L., & Willmott, C. J. (2003). *Geography in America at the dawn of the 21st century*. Oxford University Press.
- Gamo, S., Haginoya, S., Hanayama, A., Hosoya, R., Kan, M., Ishiuchi, A., & Maehira, R. (2017). Directional Consistency in Crime Location Choice for Residential Burglary in Japan. *Japanese Journal of Forensic Science and Technology*, 22(2), 153–160. <https://doi.org/10.3408/jafst.721>
- Gao, F., W. Kihal, N. Le Meur, M. Souris, and S. Deguen. (2017). Does the edge effect impact on the measure of spatial accessibility to healthcare providers? *International Journal of Health Geographics* 16 (1): 46. doi:10.1186/s12942-017-0119-3.
- Garrido Genovés, V., & López Lucio, P. (2014). *El rastro del asesino: El perfil psicológico de los criminales en la investigación policial*. Barcelona. Editorial Planeta.
- Gatrell, A. C., Bailey, T. C., Diggle, P. J., & Rowlingson, B. S. (1996). *Spatial Point Pattern*

- Analysis and Its Application in Geographical Epidemiology. *Transactions of the Institute of British Geographers*, 21(1), 256–274. <https://doi.org/10.2307/622936>
- Gigerenzer, G., & Goldstein, D. G. (1996). Reasoning the fast and frugal way: models of bounded rationality. *Psychological Review*, 103(4), 650–669.
<https://doi.org/https://doi.org/10.1037/0033-295X.103.4.650>
- Glimm, E. (1996). Fisher, N. I.: Statistical Analysis Of Circular Data. Cambridge University Press, Cambridge, UK 1995. 277 pp., £ 16.95. *Biometrical Journal*, 38(3), 314.
<https://doi.org/https://doi.org/10.1002/bimj.4710380307>
- Glyde, J. (1856). Localities of crime in suffolk. *Journal of the Statistical Society of London*, 19(2), 102–106.
- Godwin, M. (2000). *Hunting Serial Predators: A Multivariate Classification Approach to Profiling Violent Behavior* (1st ed.). CRC Press.
<https://doi.org/https://doi.org/10.1201/9781351073240>
- Godwin, M. (2001a). *Criminal Psychology and Forensic Technology*. (1st ed.). CRC Press.
<http://www.investigativepsych.com>
- Godwin, M. (2001b). *Predator* (Versión 1.1)[Software]. (Software sin acceso).
<https://directory.campbell.edu/people/maurice-godwin/>
- Godwin, M., & Canter, D. (1997). Encounter and death: The spatial behavior of US serial killers. *Policing An International Journal of Police Strategies Management*, 20(1), 24–38.

<https://doi.org/10.1108/13639519710161999>

Goodchild, M. F., & Haining, R. P. (2004). GIS and spatial data analysis: Converging perspectives. *Papers in Regional Science*, 83(1), 363–385. <https://doi.org/10.1007/s10110-003-0190-y>

Goodwill, A., & Alison, L. J. (2005). Sequential angulation, spatial dispersion and consistency of distance attack patterns from home in serial murder, rape and burglary. *Psychology, Crime and Law*, 11(2), 161–176. <https://doi.org/10.1080/10683160512331316352>

Goodwill, A., van der Kemp, J.J., Winter, J.M. (2014). Applied Geographical Profiling. In: Bruinsma, G., Weisburd, D. (eds) *Encyclopedia of Criminology and Criminal Justice*. Springer, New York, NY. https://doi.org/10.1007/978-1-4614-5690-2_2072

Górski, M. (2018a). Buffer zone and circle theory on the example of Burglaries and robberies. *Problems of Forensic Sciences*, 113, 51–66.

Górski, M. (2018b). The distance covered by perpeTraTors and Their behaviour at The scene of The incident in The case of burglaries and robberies. *Problems of Forensic Sciences*, 113, 27–50.

Gregory, N. (2005). Offender profiling: A review of the literature. *The British Journal of Forensic Practice*, 7(3), 29–34. <https://doi.org/10.1108/14636646200500019>

Grierson, B. (2003). The hound of the data points. *Popular Science* [archivo PDF]. Recuperado de hrome-

extension://efaidnbmnnnibpcajpcgclefindmkaj/https://web.mit.edu/allanmc/www/popsci.l.p
df

Grubestic, T., & Murray, A. (2001). Detecting hot-spots using cluster analysis and gis.[Sesión de conferencia] *5th Annual International Crime Mapping Research Conference*.

Guetterman, T. C., & Fetters, M. D. (2018). Two Methodological Approaches to the Integration of Mixed Methods and Case Study Designs: A Systematic Review. *American Behavioral Scientist*, *62*(7), 900–918. <https://doi.org/10.1177/0002764218772641>

Günther, F., & Fritsch, S. (2010). Neuralnet: Training of neural networks. *R Journal*, *2*(1), 30–38. <https://doi.org/10.32614/rj-2010-006>

Guptill, S., & Morrison, J. (1995). *Elements of Spatial Data Quality* (J. L. M. S.C. Guptill (Ed.); 1st Editio). Elsevier Science Inc. [https://doi.org/10.1016/S0098-3004\(97\)87525-5](https://doi.org/10.1016/S0098-3004(97)87525-5)

Gurian, E. A. (2017). Reframing Serial Murder Within Empirical Research: Offending and Adjudication Patterns of Male, Female, and Partnered Serial Killers. *International Journal of Offender Therapy and Comparative Criminology*, *61*(5), 544–560. <https://doi.org/10.1177/0306624X15598572>

Haggett, P. (1994). *Geografía. Una síntesis moderna*. Omega Editorial.

Halás, M., Klapka, P., & Kládivo, P. (2014). Distance-decay functions for daily travel-to-work flows. *Journal of Transport Geography*, *35*, 107–119. <https://doi.org/https://doi.org/10.1016/j.jtrangeo.2014.02.001>

- Hamilton, B. (2022). 2,000 serial killers in US, says man who caught Golden State Killer. *New York Post*. Recuperado de <https://nypost.com/2022/04/30/the-us-has-2000-serial-killers-says-man-who-caught-golden-state-killer/>
- Hammond, L., & Youngs, D. (2011). Decay functions and criminal spatial processes: Geographical offender profiling of volume crime. *Journal of Investigative Psychology and Offender Profiling*, 8(1), 90–102. <https://doi.org/10.1002/jip.132>
- Hanyu, K. (2019). *Geographical Offender Profiling with Spreadsheet* [archivo PDF]. Recuperado de https://www.researchgate.net/publication/336243119_Geographical_Offender_Profiling_with_Spreadsheet
- Hargrove, T. (2021). *Murder Accountability Project*. Recuperado de <http://www.murderdata.org>
- Harris, T. (1988). *The Silence of the Lambs*. Martin's Press.
- Hayford, J. F. (1902). What is the Center of An Area, or the Center of a Population? *Publications of the American Statistical Association*, 8(58), 47–58. <https://doi.org/10.2307/2276137>
- Hernández Sampieri, R., Fernández Collado, C., & Baptista, P. (2010). *Metodología de la Investigación*. México. Mc Graw Hill.
- Hewitt, R., Parfitt, S., & Wenban-Smith, F. (2018). *Rose diagrams and statistical tests for archaeological orientation data: a case applied to the Southfleet Road Elephant site, Ebbsfleet, UK*. 31–34. <https://doi.org/10.31235/osf.io/f2vzs>
- Hickey, E.W. (2015). *Serial murderers and their victims* (7th ed.). Wadsworth, Cengage

Learning.

- Hodgkinson, S., Prins, H., & Stuart-Bennett, J. (2017). Monsters, madmen... and myths: A critical review of the serial killing literature. *Aggression and Violent Behavior, 34*, 282–289. <https://doi.org/https://doi.org/10.1016/j.avb.2016.11.006>
- Holmes, R.M, & Holmes, S. T. (1998). *Serial murder* (2nd ed). Sage.
- Holmes, R., & Holmes, T. (1994). *Murder in America*. Thousand Oaks,CA: Sage.
- Holmes, R. M., & De Burger, J. (1988). *Serial Murder*. Beverly Hills,CA:Sage.
- Horton, F. E., & Reynolds, D. R. (1971). Effects of Urban Spatial Structure on Individual Behavior. *Economic Geography, 47*(1), 36–48. <https://doi.org/10.2307/143224>
- Hosmer, D. W., & Lemeshow, S. (2000). *Applied Logistic Regression* (pp. 1–375). John Wiley & Sons. <https://doi.org/10.1002/0471722146>
- Igel, C., & Hüsken, M. (2003). Empirical evaluation of the improved Rprop learning algorithms. *Neurocomputing, 50*, 105–123. [https://doi.org/10.1016/S0925-2312\(01\)00700-7](https://doi.org/10.1016/S0925-2312(01)00700-7)
- Ioana, I. M. (2013). No One is Born a Serial Killer! *Procedia - Social and Behavioral Sciences, 81*, 324–328. <https://doi.org/https://doi.org/10.1016/j.sbspro.2013.06.436>
- Iyigun, C., & Ben-Israel, A. (2010). A generalized Weiszfeld method for the multi-facility location problem. *Operations Research Letters, 38*(3), 207–214. <https://doi.org/https://doi.org/10.1016/j.orl.2009.11.005>

- Jackson, J. L., & Bekerian, D. A. (1997). Offender profiling: Theory, research and practice. In Janet L Jackson & D. A. Bekerian (Eds.), *Offender profiling: Theory, research and practice*. John Wiley & Sons Inc.
- Jenkins, P. (1993). African-Americans and serial homicide. *American Journal of Criminal Justice*, 17(2), 47–60. <https://doi.org/10.1007/BF02885953>
- Joyanes Aguilar, L. (2001). *Fundamentos de programación, algoritmos y estructura de datos* (2 ed). Mc Graw Hill.
- Kahneman, D., & Tversky, A. (1979). Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, 47(2), 263–291. <https://doi.org/10.2307/1914185>
- Kanevski, M., Timonin, V., & Pozdnukhov, A. (2009). *Machine Learning for Spatial Environmental Data: Theory, Applications, and Software* (1st ed). EPFL Press. <https://doi.org/https://doi.org/10.1201/9781439808085>
- Kaplan, R., Schuck, N. W., & Doeller, C. F. (2017). The Role of Mental Maps in Decision-Making. *Trends in Neurosciences*, 40(5), 256–259. <https://doi.org/10.1016/j.tins.2017.03.002>
- Kasprzyk, J.-P., Trotta, M., Broxham, K., & Donnay, J.-P. (2013). Reconstitution of the Journeys to Crime and Location of Their Origin in the Context of a Crime Series. A Raster Solution for a Real Case Study. In M. Leitner (Ed.), *Crime Modeling and Mapping Using Geospatial Technologies* (pp. 125–143). Springer Netherlands. https://doi.org/10.1007/978-94-007-4997-9_6

- Keeney, B. T., & Heide, K. M. (1994). Gender differences in serial murderers: A preliminary analysis. *Journal of Interpersonal Violence, 9*(3), 383–398.
- Kent, J. (2003). *Using functional distance measures when calibrating journey-to-crime distance decay algorithms*. December, 1–121. papers2://publication/uuid/A482D5D7-19BC-49BE-87E7-8CD769AD9FBA%5Cnfile:///C:/Users/??/AppData/Local/Mendeley Ltd./Mendeley Desktop/Downloaded/Kent - 2003 - Using functional distance measures when calibrating journey-to-crime distance decay algorithms.pdf
- Kent, J. (2009). *Essays on the integration of anisotropic landscapes within contemporary geographic profiling models* [Tesis de doctorado, Louisiana State University].
https://digitalcommons.lsu.edu/gradschool_dissertations/2903
- Kent, J., & Leitner, M. (2007). *Efficiency of Standard Deviation Ellipses in the Application of Criminal Geographic Profiling*. *165*, 147–165.
- Kent, J., & Leitner, M. (2009). Utilizing Land Cover Characteristics to Enhance Journey-to-Crime Estimation Models. *Crime Mapping: A Journal of Research and Practice, 33–54*.
- Kent, J., & Leitner, M. (2012). Incorporating Land Cover within Bayesian Journey-to-crime Estimation Models. *International Journal of Psychological Studies, 4*(2), 120–140.
<https://doi.org/10.5539/ijps.v4n2p120>
- Kent, J., Leitner, M., & Curtis, A. (2006). Evaluating the Usefulness of Functional Distance Measures When Calibrating Journey-to-Crime Distance Decay Functions. *Computers, Environment and Urban Systems, 30*, 181–200.

<https://doi.org/10.1016/j.compenvurbsys.2004.10.002>

- Kerr, G. (2011). *Mapping the Trail of a Crime: How Experts Use Geographic Profiling to Solve the World's Most Notorious* (Readers Digest (Ed.)).
- Ketelaar, J. (2015). *It is all about the circle : An inventory of circular data*. [Tesis de maestría no publicada], Utrecht University.
- Kiger, K. (1990). The darker figure of crime: The serial murder enigma. *Serial Murder: An Elusive Phenomenon*, 33–52.
- Kind, S. S. (1987). Navigational ideas and the Yorkshire Ripper investigation. *Journal of Navigation*, 40, 385–393.
- Kitchin, R. M. (1994). Cognitive maps: What are they and why study them? *Journal of Environmental Psychology*, 14(1), 1–19. [https://doi.org/10.1016/S0272-4944\(05\)80194-X](https://doi.org/10.1016/S0272-4944(05)80194-X)
- Knafl, K., & Breitmayer, B. (1991). *Triangulation in qualitative research: issues of conceptual clarity and purpose*. In *Qualitative Nursing Research: A Contemporary Dialogue* (pp. 226-239). SAGE Publications, Inc., <https://doi.org/10.4135/9781483349015>
- Kocsis, R. N. (2007). Skills and accuracy in criminal profiling. *Criminal Profiling: International Theory, Research, and Practice*, 47(2003), 365–382. https://doi.org/10.1007/978-1-60327-146-2_18
- Kocsis, R. N., Cooksey, R. W., Irwin, H. J., & Allen, G. (2002). A Further Assessment of “Circle Theory” for Geographic Psychological Profiling. *Australian & New Zealand Journal of*

Criminology, 35(1), 43–62. <https://doi.org/10.1375/acri.35.1.43>

Kocsis, R. N., & Irwin, H. J. (1997). An analysis of spatial patterns in serial rape, arson, and burglary: The utility of the circle theory of environmental range for psychological profiling. *Psychiatry, Psychology and Law*, 4(2), 195–206.
<https://doi.org/10.1080/13218719709524910>

Kocsis, R. N., & Palermo, G. B. (2015). Disentangling criminal profiling: Accuracy, homology, and the myth of trait-based profiling. In *International Journal of Offender Therapy and Comparative Criminology* (Vol. 59, Issue 3, pp. 313–332). Sage Publications.
<https://doi.org/10.1177/0306624X13513429>

Koppen, P.J. van, & van der Kemp, J. (2010). Psychologische en geografische profielen. *Reizen Met Mijn Rechter: Psychologie van Het Recht*, 219–252.

Kraemer, G. W., Lord, W. D., & Heilbrun, K. (2004). Comparing single and serial homicide offenses. *Behavioral Sciences & the Law*, 22(3), 325–343. <https://doi.org/10.1002/bsl.581>

Krueckeberg, D. A., & Silvers, A. L. (1974). *Urban Planning Analysis: Methods and Models*. John Wiley & Sons.

Ksenija B, Jelena M. Geography of Crime and Geographic Information Systems. *J Forensic Sci & Criminal Inves.*2017:2(4). <https://doi.org/10.19080/JFSCI.2017.02.555591>

Kuhn, H. W. (1973). A Note on fermat's problem. *Mathematical Programming* 4, 98–107 (1973). <https://doi.org/10.1007/BF01584648>

- Lange, R. (1999). A Cusp Catastrophe Approach to the Prediction of Temporal Patterns in the Kill Dates of Individual Serial Murderers. *Nonlinear Dynamics, Psychology, and Life Sciences*, 3(2), 143–159. <https://doi.org/10.1023/A:1022079306321>
- Laukkanen, M. (2007). *Geographic Profiling : Using home to crime distances and crime features to predict offender home location* [Tesis de doctorado, Åbo Akademi University]. <https://www.researchgate.net/publication/274697121%0AGeographic>
- Laukkanen, M., & Santtila, P. (2006). Predicting the residential location of a serial commercial robber. *Forensic Science International*, 157(1), 71–82. <https://doi.org/10.1016/j.forsciint.2005.03.020>
- Le Comber, S. ., Nicholls, B., Rossmo, D. K., & Racey, P. A. (2006). Geographic profiling and animal foraging. *Journal of Theoretical Biology*, 2, 233–240.
- LeBeau, J. L. (1987a). The journey to rape: Geographic distance and the rapist's method of approaching the victim. *Journal of Police Science & Administration*, 15(2), 129–136.
- LeBeau, J. L. (1987b). The Methods and Measures of Centrography and the Spatial Dynamics of Rape. *Journal of Quantitative Criminology*, 3(2), 125–141. <https://www.jstor.org/stable/23365618>
- Leitner, M., Kent, J., Oldfield, I., & Swoope, E. (2007). Geoforensic Analysis Revisited—The Application of Newton's Geographic Profiling Method to Serial Burglaries in London, UK. *Police Practice and Research*, 8(4), 359–370. <https://doi.org/10.1080>. *Police Practice and Research*, 8(4), 359–370. <https://doi.org/10.1080/15614260701615060>

- León, O., & Montero, I. (2018). Métodos de investigación en psicología y educación / Orfelio G. León, Ignacio Montero. *SERBIULA (Sistema Librum 2.0)*.
- Leone, A., Raastad, C., & Tolkov, I. (2010). *Yet Another Mathematical Approach to Geographic Profiling*. 1–21. <http://www.math.washington.edu/~morrow/mcm/mcm.html>
- LePard, D. (2010). *Missing Women Investigation Review*. 268-274, [archivo PDF] Recuperado <https://vpd.ca/wp-content/uploads/2021/06/missing-women-investigation-review.pdf>
- Levin, J., & Fox, J. A. (1985). Mass murder: The growing menace. *New York: Plenum Press*.
- Levine, N. (2002). *Crimestat: A Spatial Statistics Program for the Analysis of Crime Incident Locations (v2.0)*. Ned Levine and Associates and the National Institute of Justice. www.icpsr.umich.edu/NACJD/crimestat.html
- Levine, N. (2004). “*Journey to crime Estimation*”. Chapter 10 of Ned Levine (ed), *CrimeStat III: A Spatial Statistics Program for the Analysis of Crime Incident Locations (version 3.0)*. Ned Levine & Associates, Houston, TX.; National Institute of Justice, Washington, DC. <http://www.icpsr.umich.edu/crimestat>.
- Levine, N. (2005). *The evaluation of geographic profiling software: response to Kim Rossmo’s critique of the NIJ methodology*. [http://www.nedlevine.com/Response to Kim Rossmo Critique of the GP Evaluation Methodology.May 8 2005.doc](http://www.nedlevine.com/Response%20to%20Kim%20Rossmo%20Critique%20of%20the%20GP%20Evaluation%20Methodology.May%208%202005.doc)
- Levine, N. (2006). Crime mapping and the crimestat program. *Geographical Analysis*, 38(1), 41–56. <https://doi.org/10.1111/j.0016-7363.2005.00673.x>

- Levine, N. (2015). *CrimeStat: Spatial Statistics Program for the Analysis of Crime Incident Locations* (Versión 4.02) [Software]. Ned Levine & Associates, Houston, Texas, and the National Institute of Justice, Washington, D.C. August.
<https://nij.ojp.gov/topics/articles/crimestat-spatial-statistics-program-analysis-crime-incident-locations>
- Levine, N., & Associates. (2013). CrimeStat IV: A Spatial Statistics Program for the Analysis of Crime Incident Locations (V. 4). *Journal of Chemical Information and Modeling*, 53, 1–1797.
- Levine, N., & Block, R. (2011). Bayesian journey-to-crime estimation: An improvement in geographic profiling methodology. *The Professional Geographer*, 63(2), 213–229.
<https://doi.org/10.1080/00330124.2010.547152>
- Lewis, N. (2016). Circular Statistics in R A. Pewsey, M. Neuhäuser and G. D. Ruxton, 2013 Oxford, Oxford University Press 184 pp., £ 24.99 ISBN 978-0-199-67113-7. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 179(4), 1132.
<https://doi.org/https://doi.org/10.1111/rssa.12222>
- Liem, M., Ganpat, S., Granath, S., Hagstedt, J., Kivivuori, J., Lehti, M., & Nieuwbeerta, P. (2013). Homicide in Finland, the Netherlands, and Sweden: First Findings From the European Homicide Monitor. *Homicide Studies*, 17(1), 75–95.
<https://doi.org/10.1177/1088767912452130>
- Lino, D., Calado, B., Belchior, D., Cruz, M., & Lobato, A. (2018). Geographical offender

profiling: Dragnet's applicability on a Brazilian sample. *Journal of Investigative Psychology and Offender Profiling*, 15(2), 149–161.

<https://doi.org/https://doi.org/10.1002/jip.1497>

Liu, L., & Eck, J. (2008). Artificial Crime Analysis Systems: Using Computer Simulations and Geographic Information Systems. edited by Liu, Lin and Eck. Information Science

<https://doi.org/10.4018/978-1-59904-591-7>

Longley, J. W. (1967). An Appraisal of Least Squares Programs for the Electronic Computer from the Point of View of the User. *Journal of the American Statistical Association*, 62(319), 819–841. <https://doi.org/https://doi.org/10.2307/2283673>

Lopez-Garcia, Juan Carlos (2009). *Guía de Algoritmos y Programación para docentes*. Cali: Universidad Icesi

Lopez, M. (2006). *Geografische Daderprofilering*. [archivo PDF] Recuperado de

<https://doi.org/10.13140/RG.2.2.28187.26408>

Lowe, J. C., & Moryadas, S. (1975). *The Geography of Movement*. Boston:Houghton Mifflin.

Lundrigan, S, & Canter, D. (2001). Spatial patterns of serial murder: an analysis of disposal site location choice. *Behavioral Sciences & the Law*, 19, 595–610.

<https://doi.org/10.1002/bsl.431>

Lundrigan, Samantha, & Canter, D. (2001). A multivariate analysis of serial murderers' disposal site location choice. *Journal of Environmental Psychology*, 21(4), 423–432.

<https://doi.org/10.1006/jevp.2001.0231>

Lundrigan, Samantha, & Czarnomski, S. (2006). Spatial characteristics of serial sexual assault in New Zealand. *Australian & New Zealand Journal of Criminology*, 39(2), 218–231.

<https://doi.org/10.1375/acri.39.2.218>

Lundrigan, Samantha, Czarnomski, S., & Wilson, M. (2009). Spatial and environmental consistency in serial sexual assault. *J. Investig. Psych. Offender Profil.*, 7: 15-30. <https://doi.org/10.1002/jip.100>

M. Kathleen, H., & Stephen, E. (1991). Serial Murder: An Elusive Phenomenon. *The Journal of Criminal Law and Criminology*, 81, 1102. <https://doi.org/10.2307/1143738>

Maldonado Guzmán, D. J. (2022). *La gentrificación turística como fuente de desorganización social: un estudio de la delincuencia urbana en Barcelona*. [Tesis de doctorado, Universidad de Cádiz] <https://summit.sfu.ca/item/5157>.

Maldonado, D., & Salafranca, D. (2019). Propuesta metodológica para predecir el próximo lugar de actuación de un pederasta en serie. *International E-Journal of Criminal Science*, 14(2019), 1–12.

Mardia, K.V . (1972). *Statistics of directional data*. Academic press.

Mardia, K. V., & Jupp, P. E. (2000). *Directional Statistics*. John Wiley & Sons

Mark L. Dantzker, & Ronald D. Hunter. (2011). *Research Methods for Criminology and Criminal Justice* (3rd Editio). Jones & Bartlett Learning.

Martin, R. A., Rossmo, D. K., & Hammerschlag, N. (2009). Hunting patterns and geographic profiling of white shark predation. *Journal of Zoology*, 279(2), 111–118.

<https://doi.org/10.1111/j.1469-7998.2009.00586.x>

Masucci, C., Franchi, L., Giuntini, V., & Defraia, E. (2014). Short-term effects of a modified Alt-RAMEC protocol for early treatment of Class III malocclusion: a controlled study.

Orthodontics & Craniofacial Research, 17 4, 259–269.

McFadden, D. (1978). Quantitative Methods for Analyzing Travel Behaviour of Individuals: Some Recent Developments. In *Behavioural Travel Modelling* (pp. 279–318).

Meaney, R. (2004). Commuters and Marauders: An Examination of the Spatial Behaviour of Serial Criminals. *Journal of Investigative Psychology and Offender Profiling*, 1, 121–137.

Melo R., C. E. (2001). *Dominios 5, matemáticas para básica primaria*. Editorial Escuelas del Futuro.

Miller, L. (2014). Serial killers: I. Subtypes, patterns, and motives. *Aggression and Violent Behavior*, 19(1), 1–11. <https://doi.org/https://doi.org/10.1016/j.avb.2013.11.002>

Mitchell, A. (2005). Spatial Measurements and Statistics. In Andy Mitchell & L. Griffin, *The ESRI Guide to GIS Analysis* (2nd ed., Vol. 2, pp. 1–20). Esri Press.

<http://esripress.esri.com/storage/esripress/images/86/twochap.pdf>

Mitchell, A. (2020). The ESRI Guide to GIS Analysis. In *ESRI Press* (2nd ed., Vol. 1). Esri Press.

- Mohler, G. O., & Short, M. B. (2012). Geographic profiling from kinetics models of criminal behaviour. *SIAM J. Appl. Math* 72(1), 163–180. <https://doi.org/10.1137/100794080>
- Mordowa, S. (2019). Geographic profiling, as the application of spatial analyses in discovering the offenders of crimes. *Sapce-Society-Economy*, 1, 51–75. <https://doi.org/10.18778/1733-3180.30.03>
- Mori, Y. (1987). Methods for Estimating the Mean and the Standard Deviation of Wind Direction. *Journal of Applied Meteorology*, 26(9), 1282–1284.
- Morrow, J. (2010). *Why Crime Doesn't Pay: Locating Criminals Through Geographic Profiling*. 1–27. <https://sites.math.washington.edu/~morrow/mcm/7272.pdf>
- Morton, R. J., Hilts, M.A., & Johns, L. (2008). Serial murders: multi-disciplinary perspective for investigators.
- Neldner, R. (2015). *Geographic Profiling of Serial Murderer, Gary Ridgway, to Assist Law Enforcement in the Apprehension of Future Serial Murderers*. 17.
- Newton, M. (2006). *The encyclopedia of serial killers*. (2th edition.). Checkmark Books.
- Newton, M. B. (1988). *Geographical discovery of the residence of an unknown dispersing localized serial murder*. [Manuscrito no publicado, Louisiana State University, Baton Rouge].
- Newton, M. B., & Newton, D. C. (1985). *Geoforensic identification of localized serial crime: unsolved female homicides*. [Presentación de paper] Fort Worth, Texas, 1983-85. Southwest

Division, Association of American Geographers, Denton, TX.

- Newton, M. B., & Swoope, E. A. (1987). *Geoforensic analysis of localized serial murder: the Hillside stranglers located*. [Presentación de paper] *In Proceedings of the 39th Annual Meeting of the American Academy of Forensic Sciences*.
- Nichols, B. (2019). *Geographic Profiling : Contributions to the Investigation of Serial Murders*. [Tesis de maestría, Wright State University]
http://rave.ohiolink.edu/etdc/view?acc_num=wright1559164233007786
- O’Leary, M. (2009). The mathematics of geographic profiling. *Journal of Investigative Psychology and Offender Profiling*, 6(3), 253–265. <https://doi.org/10.1002/jip.111>
- O’Leary, M. (2011a). Modeling criminal distance decay. *Cityscape: A Journal of Policy Development and Research*, 13(3), 161–198. <https://doi.org/10.2307/41426679>
- O’Leary, M. (2011b). *Patterns in Offender Distance Decay and the Geographic Profiling Problem . Acknowledgments*.
- Öhrn, M. (2016). *A scientific tool or merely a guessing game?* [Tesis de maestría, Malmö University] <chrome-extension://efaidnbnmnibpcajpcglclefindmkaj/https://www.diva-portal.org/smash/get/diva2:1486941/FULLTEXT01.pdf>.
- Osborne, J. R., & Salfati, C. G. (2015a). Re-conceptualizing “ cooling-off periods ” in serial homicide. *Homicide Studies: An Interdisciplinary & International Journal*, 19(2), 188–205. <https://doi.org/10.1177/1088767914526716>

- Overland Park, K. (2012). *International Association of Crime Analysts. GIS Requirements for Crime Analysis (White Paper 2012-01)*. <https://www.iaca.net/publications>
- Pal, T. (2007). *Accuracy assessment of individually calibrated journey-to crime geographic profiling models* [Tesis de maestría, Louisiana State University].
<http://etd.lsu.edu/docs/available/etd-11122007-100403/unrestricted/TaniaPalThesis.pdf>
- Papini, A., & Santosuosso, U. (2017). Snow's case revisited: New tool in geographic profiling of epidemiology. *The Brazilian Journal of Infectious Diseases: An Official Publication of the Brazilian Society of Infectious Diseases*, 21(1): 112–115.
<https://doi.org/10.1016/j.bjid.2016.09.010>
- Paruelo JM, & Tomasel F. (1997). Prediction of Functional Characteristics of Ecosystems: A Comparison of Artificial Neural Networks and Regression Models. *Ecological Modelling*, 98, 173–186. [https://doi.org/doi:10.1016/s0304-3800\(96\)01913-8](https://doi.org/doi:10.1016/s0304-3800(96)01913-8)
- Paulsen, D. (2006a). Connecting the dots: Assessing the accuracy of geographic profiling software. *Policing*, 29(2), 306–334. <https://doi.org/10.1108/13639510610667682>
- Paulsen, D. (2006b). Human versus machine: a comparison of the accuracy of geographic profiling methods. *Journal of Investigative Psychology and Offender Profiling*, 3(2), 77–89.
<https://doi.org/10.1002/jip.46>
- Paulsen, D. (2007). Improving Geographic Profiling through Commuter/Marauder Prediction. *Police Practice & Research*, 8(4), 347–357. <https://doi.org/10.1080/15614260701615045>

- Paulsen, D. (2011). *Spatial Pattern analysis for Investigative Decision making Exploration and Response* (Versión 1.5) [Software]. <https://www.criminalbehavior.com/SPIDER.html>
- Paulsen, D., Bair, S., & Helms, D. (2009). *Tactical Crime Analysis: Research and Investigation* CRC Press. <https://doi.org/10.4324/9781420086980>
- Petee, T. A., & J.Jarvis. (2000). Analyzing Violent Serial Offending: Guest Editors' Introduction. *Homicide Studies*, 4(3), 211-218. <https://doi.org/10.1177/1088767900004003001>
- Phillips, P. D. (1980). Characteristics and Typology of the Journey to Crime (From Crime - A Spatial Perspective, P 167-180, 1980, Daniel E Georges-Abeyie and Keith D Harries, ed. - See NCJ-74011). In *From Crime - A Spatial Perspective*,.
- Phoenix, X. (2014). Putting the Offender on the Map : A look into the rationality of serial offenders ' geographical behavior. *Alliant International University, September*. <https://doi.org/10.13140/2.1.4371.1362>
- Polišenská, V. A. (2008). A qualitative approach to the criminal mobility: Questioning the near-home hypothesis. *Crime Patterns and Analysis*, 1, 47–59.
- Polišenská, V. A. (2013). Interviewing offenders in a penitentiary environment and the use of mental maps during interviews. In *Offenders on Offending: Learning about Crime from Criminals*, 237–289.
- Polya, G. (1957). *How to Solve It. A New Aspect of Mathematical Method*. 2nd Edition,

Princeton University Press.

Prasad, N., Singh, R., & Lal, S. P. (2013). Comparison of back propagation and resilient propagation algorithm for spam classification. *Proceedings of International Conference on Computational Intelligence, Modelling and Simulation*, 29–34.

<https://doi.org/10.1109/CIMSim.2013.14>

Pulinckx, S. (2006). *Predicting offence styles in series of Dutch property offenders*. [Tesis de maestría no publicada, Universiteit Maastricht].

Python Core Team. (2019). *Python: A dynamic, open source programming language* (Python version 3.7).[Software] Python Software Foundation. <https://www.python.org/>

QGIS Development Team. (2022). *QGIS Geographic Information System*. (3.24) [Software] Open Source Geospatial Foundation Project. <https://qgis.org>

R Core Team. (2020). *R: A Language and Environment for Statistical Computing*. <https://www.r-project.org/>

Ramsland, K. (2005). Inside the minds of mass murderers: why they kill. *Choice Reviews Online*, 42(10), 42-6174-42-6174. <https://doi.org/10.5860/choice.42-6174>

Ratcliffe, J. H. (2006). A temporal constraint theory to explain opportunity-based spatial offending patterns. *Journal of Research in Crime and Delinquency*, 43(3), 261–291. <https://doi.org/10.1177/0022427806286566>

Ravindran, P., & Ghosh, S. K. (2011). Bayesian Analysis of Circular Data Using Wrapped

Distributions. *Journal of Statistical Theory and Practice*, 5(4), 547–561.

<https://doi.org/10.1080/15598608.2011.10483731>

Rayleigh, Lord. (1880). XII. On the resultant of a large number of vibrations of the same pitch and of arbitrary phase. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 10(60), 73–78. <https://doi.org/10.1080/14786448008626893>

Rebecca Meaney. (2004). Commuters and marauders: an examination of the spatial behaviour of serial criminals. *Journal of Investigative Psychology and Offender Profiling*, 1(2), 121–137. <http://dx.doi.org/10.1002/jip.12>

Reboussin, R., Warren, J. I., & Hazelwood, R. R. (1995). Mapless mapping in analyzing the spatial distribution of serial rapes. In & S. F. C. Block, M. Dabdoub (Ed.), *Crime analysis through computer mapping* (pp. 69–74).

Reichmann, W. J. (1961). *Use and Abuse of Statistics* (Middlesex (Ed.)). Penguin Books.

Reid, S. (2017). Developmental pathways to serial homicide: A critical review of the biological literature. *Aggression and Violent Behavior*, 35, 52–61. <https://doi.org/10.1016/j.avb.2017.06.003>

Rengert, G. F., & Lockwood, B. (2009). Geographic units of analysis and the analysis of crime. In D. Weisburd, D. Bruinsma & W. Bernasco. (Eds.). *Putting Crime in its place. Units of analysis in geographic criminology* (pp. 109-121). New York: Springer

Rengert, G. F. & Wasilchick, J. (1985). *Suburban Burglary - A Time and a Place for Everything*.

In *Springfield, Ill., U.S.A.* : C.C. Thomas, c1985.

Rengert, G. (2004). The journey to crime. In G. Bruinsma. *Punishment, Places and Perpetrators: Development in Criminology and Criminal Justice Research*, 169–181.

Rengert, G., Piquero, A. R., & Jones, P. R. (1999). Distance decay reexamined. *Criminology*, 37(2), 427–446. <https://doi.org/https://doi.org/10.1111/j.1745-9125.1999.tb00492.x>

Ressler, R. K., & Shachtman, T. (1992). *Whoever Fights Monsters*. Simon & Schuster.

Rhodes, W. M., & Conly, C. (1981). *Crime and mobility: An empirical study*. In: P. J. Brantingham & P. L. Brantingham (eds), *Environmental criminology*. Sage Publications.

Rich, T., & Shively, M. (2004). *A Methodology for Evaluating Geographic Profiling Software*.
papers2://publication/uuid/AF555A66-D44C-4F46-9B96-30755C7F50E2%5Cnfile:///C:/Users/??/AppData/Local/Mendeley Ltd./Mendeley Desktop/Downloaded/Rich, Shively - 2005 - A Methodology for Evaluating Geographic Profiling Software.pdf

Robert K. Yin. (2014). Case study research design and methods. *CJPE*, 30(1), 282.
<https://doi.org/10.3138/CJPE.BR-240>

Robinson, M. (2000). The construction and reinforcement of myths of race and crime. *Journal of Contemporary Criminal Justice.*, 16:133-156.

Rossmo, D. K. (1987). *Fugitive Migration Patterns* [Tesis de maestría, Simon Fraser University]
<https://summit.sfu.ca/item/5157>.

- Rossmo, D. K. (1995). Geographic profiling: Target patterns of serial murderers. *ProQuest Dissertations and Theses, October*, 581-581 p.
http://search.proquest.com/docview/304262001?accountid=14553%5Cnhttp://openurl.library.uiuc.edu/sfxlcl3?url_ver=Z39.88-2004&rft_val_fmt=info:ofi/fmt:kev:mtx:dissertation&genre=dissertations+&+theses&sid=ProQ:ProQuest+Dissertations+&+Theses+Full+Text&atitl
- Rossmo, D. K. (1997a). Geographic profiling. In *Offender profiling: Theory, research and practice*. (pp. 159–175). John Wiley & Sons Inc.
- Rossmo, D. K. (1997b). Place , Space , and Police Investigations : Hunting Serial. *Simon Fraser University*, 18.
- Rossmo, D. K. (1997c). *Rigel* (Versión 2.8) [Software]. Environmental Criminology Research Inc. (ECRI)Environmental Criminology Research Inc. (ECRI). www.ecricanada.com
- Rossmo, D. K. (1998a). *Environmental Criminology Research* (Patent No. US5781704C1).
<https://patents.google.com/patent/US5781704C1/en>
- Rossmo, D. K. (1998b). *U.S.* (Patent No. 5,781,704). Patent and Trademark Office.
- Rossmo, D. K. (1999). *Geographic profiling* (CRC (Ed.)). Boca Raton.
<https://doi.org/doi.org/10.1201/9781420048780>
- Rossmo, D. K. (2000). *Geographic Profiling* . Boca Raton, FL: CRC.
- Rossmo, D. K. (2005a). *An Evaluation of NIJ's Evaluation Methodology for Geographic*

Profiling Software.

- Rossmo, D. K. (2005b). Geographic heuristics or shortcuts to failure?: response to Snook et al. *Applied Cognitive Psychology, 19*(5), 651–654. <https://doi.org/10.1002/acp.1144>
- Rossmo, D. K. (2011). Evaluating geographic profiling. *Crime Mapping. A Journal of Research and Practice, 3*, 42–65.
- Rossmo, D. K. (2013). *Geographic profiling*. In Encyclopedia of criminology and criminal justice, ed. G. Bruinsma & D.L. Weisburd, 1934-42. New York: Springer.
- Rossmo, D. K. (2022). Bayesian Geographic Profiling: A Fundamental Limitation. *The Professional Geographer, 74*(4), 772–780. <https://doi.org/10.1080/00330124.2022.2075408>
- Rossmo, D. K., Laverly, I., & Moore, B. (2005). Geographic Profiling for Serial Crime Investigation. In IGI Global (Ed.), *Geographic Information Systems and Crime Analysis* (In Wang, F, pp. 102–117). <https://doi.org/10.4018/978-1-59140-453-8.ch006>
- Rossmo, D. K., & Summers, L. (2015). El Perfil Geográfico en la Investigación Criminal. *International E-Journal of Criminal Science, 9*(2015), 1–24.
- Rossmo, D. K., Thurman, Q., Jamieson, J., & Egan, K. (2008). Geographic Patterns and Profiling of Illegal Crossings of the Southern U.S. Border. *Security Journal, 21*. <https://doi.org/10.1057/palgrave.sj.8350067>
- Rutishauser, U., Ross, I. B., Mamelak, A. N., & Schuman, E. M. (2010). Human memory strength is predicted by theta-frequency phase-locking of single neurons. *Nature*,

464(7290), 903–907. <https://doi.org/10.1038/nature08860>

Salafranca Barreda, D. (2020). The application of Newton and Swoope's geographical profile to serial killers. *Journal of Investigative Psychology and Offender Profiling*, 18(1), 68–78.

<https://doi.org/10.1002/jip.1566>

Salafranca Barreda, D. (2023). *GEO-SCRIPT* (1.1) [Software]. <https://geoscript.shinyapps.io/GEO-SCRIPT/>

Salafranca, D., & Maldonado, D. J. (2018). Perfil geográfico de incendiarios urbanos Geographic profiling of urban arsonists. *Revista Española de Investigación Criminológica*, 16(2018), 1–34. www.criminologia.net

Salafranca Barreda, Maldonado-Guzman & Saldaña-Taboada (2022). Crime beyond the edge: development of a tool to correct the edge effect on crime count, *Annals of GIS*, 28:3, 279–292. <https://doi.org/10.1080/19475683.2022.2052748>

Salafranca, D., & Rodríguez, M. (2015). Análisis delictivo con gvSIG CRIME. *Mapping*, 24(169), 42–56.

Salafranca, D., & Yaksic, E. (2022). Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders. *Journal of Police and Criminal Psychology*, 0123456789.

<https://doi.org/10.1007/s11896-022-09561-3>

Saleh, H., & Layous, J. A. (2022). Machine Learning – Regression By : *Research Gate*, January, 25. <https://doi.org/10.13140/RG.2.2.35768.67842>

- Salste, T. (2021). *Visustin* (No. 8) [Software]. Aivosto. <https://www.aivosto.com/visustin.html>
- Sammons, A., & Putwain, D. (2018). Psychology and Crime. In Routledge (Ed.), *Psychology and Crime* (2nd ed., pp. 67–85). <https://doi.org/https://doi.org/10.4324/9781351252140>
- Sanhouse, A. J. (2018). *Planificación Forestal y Gestión Territorial, Mediante Herramientas Open Source e Imágenes de Satélites*. Universidad de Córdoba.
- Santtila, P., Zappalà, A., Laukkanen, M., & Picozzi, M. (2003). Testing the utility of a geographical profiling approach in three rape series of a single offender: a case study. *Forensic Science International*, *131*(1), 42–52. [https://doi.org/https://doi.org/10.1016/S0379-0738\(02\)00385-7](https://doi.org/https://doi.org/10.1016/S0379-0738(02)00385-7)
- Sarría, A. F. (2006). *Sistemas de Información Geográfica*. Recuperado en <https://www.um.es/geograf/sigmur/sigpdf/temario.pdf>.
- Schaefer, F. K. (1988). *Excepcionalismo en geografía* (Edicions Universitat Barcelona. (Ed.)).
- Schildt, H. (2002). *C++: The Complete Reference*. McGraw Hill. 4th ed.
- Schlesinger, L. B., Ramirez, S., Tusa, B., Jarvis, J. P., & Erdberg, P. (2017). Rapid-sequence serial sexual homicides. *The Journal of the American Academy of Psychiatry and the Law*, *45*(1), 72–80.
- Schmitz, P. (2004). *Geographical profiling*. CSIR Technical Report TR- 2004/71. Pretoria, South Africa: Council for Scientific and Industrial Research.

- Schunk, D. H. (1997). *Teorías de aprendizaje* (segunda ed). Prentice Hall.
- Shaw, C. R., & McKay, H. D. (1942). *Juvenile Delinquency and Urban Areas*. University of Chicago Press.
- Simkin, M. V., & Roychowdhury, V. P. (2015). Statistical study of time intervals between murders for serial killers. *Journal of Criminal Justice*.
<https://doi.org/10.1016/j.jcrimjus.2020.101751>
- Simon, H. A. (1992). What is an “Explanation” of Behavior? *Psychological Science*, 3(3), 150–161. <https://doi.org/10.1111/j.1467-9280.1992.tb00017.x>
- Simonetti, C. (1984). *Serial murders*. State University of New York at Albany.
- Smith, J. N. M., & Sweatman, H. P. A. (1974). Food-searching behavior of titmice in patchy environments. *Ecology*, 55, 1216–1232.
- Snook, B., Canter, D., & Bennell, C. (2002). Predicting the home location of serial offenders: a preliminary comparison of the accuracy of human judges with a geographic profiling system. *Behavioral Sciences & the Law*, 20(1–2), 109–118. <https://doi.org/10.1002/bsl.474>
- Snook, B., Cullen, R. M., Mokros, A., & Harbort, S. (2005). Serial murderers’ spatial decisions: factors that influence crime location choice. *Journal of Investigative Psychology and Offender Profiling*, 2(3), 147–164. <https://doi.org/10.1002/jip.35>
- Snook, B., Taylor, P. J., & Bennell, C. (2004). Geographic profiling: the fast, frugal, and accurate way. *Applied Cognitive Psychology*, 18(1), 105–121.

<https://doi.org/10.1002/acp.956>

Snook, B., Taylor, P. J., & Bennell, C. (2005). Commentary: Shortcuts to Geographic profiling success: A reply to Rossmo (2005). *Applied Cognitive Psychology, 19*(5), 655–661.

<https://doi.org/10.1002/acp.1142>

Snook, B., Zito, M., Bennell, C., & Taylor, P. J. (2005). On the complexity and accuracy of geographic profiling strategies. *Journal of Quantitative Criminology, 21*(1), 1–25.

<https://doi.org/10.1007/s10940-004-1785-4>

Spaulding, J., & Morris, K. (2021). *rgeoprofile: Geographic Profiling Methods for Serial Crime Analysis* (R package version 0.2.2) [Software]. <https://github.com/JSSpaulding/rgeoprofile>

Spaulding, J. S., & Morris, K. B. (2023). Prediction of serial perpetrator residence: Part II—Evaluation of prediction model accuracy. *Journal of Investigative Psychology and Offender Profiling, 20*(1), 97–118. <https://doi.org/https://doi.org/10.1002/jip.1606>

Stangeland, P. (2005). Catching a Serial Rapist: Hits and Misses in Criminal Profiling. *Police Practice and Research, 6*(5), 453–469. <https://doi.org/10.1080/15614260500433079>

Stevenson, M. D. (2015). *Geographic Profiling in Biology*. [Tesis de doctorado, Queen Mary University of London]. <http://qmro.qmul.ac.uk/jspui/handle/123456789/9061>

Stewart, J. Q. (1950). The development of social physics. *American Journal of Physics, 18*, 239–53.

Stopher, P. R., & Meyburg, A. H. (1975). *Urban Transportation Modeling and Planning*.

Lexington Books.

- Suarez-meaney, T., & Chias, L. (2017). Locacional predictability and geographic profiling in serial homicide with gvSIG. Case Barraza. *Mapping*, 26(May), 52–63.
- Sviatlovsky, E. E., & Eells, W. C. (1937). The Centrophical Method and Regional Analysis. *Geographical Review*, 27(2), 240–254. <https://doi.org/10.2307/210093>
- Synnott, J., Bakker, M., Ioannou, M., Canter, D., & van der Kemp, J. (2019). Crime location choices: A geographical analysis of German serial killers. *Journal of Investigative Psychology and Offender Profiling*, 16(2), 110–123. <https://doi.org/https://doi.org/10.1002/jip.1521>
- Synnott, J., Canter, D., Youngs, D., & Ioannou, M. (2016). Variations in the Journey from Crime: Examples from Tiger Kidnapping. *Journal of Investigative Psychology and Offender Profiling*, 13(3), 239–252. <https://doi.org/https://doi.org/10.1002/jip.1454>
- Tobias, J. (1972). Urban crime in victorian England New York. In Schocken Books (Ed.), *Urban Life and Culture* (Vol. 2, Issue 1). SAGE Publications. <https://doi.org/10.1177/089124167300200114>
- Tobler, W. (1970). A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, 234–240.
- Townsley, M., & Sidebottom, A. (2010). All offenders are equal, but some are more equal than others: Variation in journeys to crime between offenders. *Criminology*, 48(3), 897–917.

<https://doi.org/10.1111/j.1745-9125.2010.00205.x>

Trotta, M. (2014). *Modelling serial offenders' spatial behaviours : new assumptions for geographic profiling* [Tesis de doctorado, University of Liège].

https://www.researchgate.net/publication/321621712_Modelling_serial_offenders'_spatial_behaviours_new_assumptions_for_geographic_profiling

Trotta, M., Lemaître, A., & Donnay, J. P. (2013). Operationality of geographic profiling through a hypothetico-deductive method. A review of constraints and factors. *BSGLg*, 60(1), 45–57.

Tukel, E. (2021). *Assessing Spatial Behavior Focusing on the Day and the Night Differences Using Social Media, GIS, and Spatial Statistics*. July.

<https://doi.org/10.13140/RG.2.2.26969.65120>

Turnbull, L.S., Hendrix, E. Hallisey., & Dent, B. D. (2000). *Atlas of crime: mapping the Criminal Landscape / [edited by] Linda S. Turnbull, Elaine Hallisey Hendrix, Borden D. Dent*. Oryx Press.

Turner, S. (1969). Delinquency and distance. In T.Sellen, & M.E. Wolfgang (Eds.),

Delinquency: Selected studies. University Press

Turvey, B. E. (2016). Applied Criminal Profiling: An Introduction. In *Behavioral Evidence Analysis: International Forensic Practice and Protocols*. <https://doi.org/10.1016/B978-0-12-800607-8.00001-X>

van der Kemp, J. (2014). *Modus via: Verfijning van geografische daderprofilering*. Vrije

Universiteit. <https://research.vu.nl/es/publications/38e99649-f9d3-4dd7-b2da-0cba54c5793b>

van Der Kemp, J., Colenbrander, H., & Duursma, R. (2005). Daderinterviews als methode van locatiekeuzeonderzoek. *Vereniging Voor Kriminologie Marktdag*, 16.

van Der Kemp, J., & van Koppen, P. J. (2007). Fine-tuning geographical profiling. *Criminal Profiling: International Theory, Research, and Practice*, 347–364.
https://doi.org/10.1007/978-1-60327-146-2_17

van Koppen, Peter J., & De Keijser, J. W. (1997). Desisting distance decay: On the aggregation of individual crime trips. *Criminology*, 35(3), 505–515. <https://doi.org/10.1111/j.1745-9125.1997.tb01227.x>

van Koppen, Peter J., van der Kemp, J., & de Poot, C. J. (2002). Geografische daderprofilering. In Kluwer (Ed.), *Het recht van binnen: Psychologie van het recht* (pp. 237–254).

van Roy, P. (2007). Self management and the future of software design. *Electronic Notes in Theoretical Computer Science*, 182, 201–217.

Vardi, Y., & Zhang, C. H. (2000). The multivariate L1-median and associated data depth. *Proceedings of the National Academy of Sciences of the United States of America*, 97(4), 1423–1426. <https://doi.org/10.1073/pnas.97.4.1423>

Veall, M. R., & Zimmermann, K. F. (1996). Pseudo-R2 measures for some common limited dependent variable models. *Journal of Economic Surveys*, 10(3).

<https://doi.org/10.1111/j.1467-6419.1996.tb00013.x>

Verity, B. (2014). *RgeoProfile: Dirichlet Process Mixture (DPM) model of geographic profiling* (Versión 2.1.0) [Software].

<https://rdr.io/github/bobverity/Rgeoprofile/man/RgeoProfile.html#heading-0>

Von Neumann, J., & Morgenstern, O. (1944). Theory of games and economic behavior. In *Theory of games and economic behavior*. Princeton University Press.

Vozmediano, L., Martín-fernández, N., Juan, C. S., Rodríguez, I., Bastarrika, A., Vasco, P., & Upv, C. (2017). Geometría de la movilidad en los delitos de agresión sexual con agresor desconocido : más allá del “ journey-to-crime .” *International E-Journal of Criminal Science*, 11(4), 1–18. <http://www.ehu.es/inecs%0A>

Wainwright, J. & Mugillan, M. (2004). *Environmental modelling: finding simplicity in complexity*. Chichester: Wiley, p. 319 - 334

Wang, F. (2012). Why police and policing need GIS: An overview. *Annals of GIS*, 18(3), 159–171. <https://doi.org/10.1080/19475683.2012.691900>

Wang, N., Qi, X., Li, G., & Li, J. (2018). *Strategy Model Based on Geographic Profiling*. 65(Cimns), 196–198. <https://doi.org/10.2991/cimns-18.2018.44>

Warren, J. I., Reboussin, R., & Hazelwood, R. R. (1995). *The geographic and temporal sequencing of serial rape: (Final Report,NIJ Publication N°.91-IJ-R027)*. Washington, DC: National Criminal Justice Reference Service.

- Warren, J. I., Reboussin, R., Hazelwood, R. R., Cummings, A., Gibbs, N., & Trumbetta, S. (1998). Crime scene and distance correlates of serial rape. *Journal of Quantitative Criminology*, *14*(1), 35–59. <https://doi.org/10.1023/A:1023044408529>
- Weisburd, D., & McEwen, T. (1997). Introduction: Crime mapping and crime prevention. Monsey: Willow Tree Press
- Więckowski, M., Michniak, D., Bednarek-Szczepańska, M., Chrenka, B., Ira, V., Komornicki, T., Rosik, P., Stępnia, M., Székely, V., Śleszyński, P., Świątek, D., & Wiśniewski, R. *Pogranicze polsko-słowackie : dostępność transportowa a turystyka*. Instytut Geografii i Przestrzennego Zagospodarowania PAN ; [archivo PDF] Recuperado de http://www.rcin.org.pl/Content/19366/PDF/WA51_39095_PAN149006-r2012_Pogranicze-pol-slowc.pdf
- Wikström, P.O.H., Mann, R. P., & Hardie, B. (2018). Young people's differential vulnerability to criminogenic exposure: Bridging the gap between people- and place-oriented approaches in the study of crime causation. *European Journal of Criminology*, *15*(1), 10–31. <https://doi.org/10.1177/1477370817732477>
- Wikström, P.O.H., & Treiber, K. (2007). The Role of Self-Control in Crime Causation: Beyond Gottfredson and Hirschi's General Theory of Crime. *European Journal of Criminology*, *4*(2), 237–264. <https://doi.org/10.1177/1477370807074858>
- Wolpert, J. (1964). The decision process in spatial context. *Annals of the Association of American Geographers*, 537–558.

- Woodworth, M., & Porter, S. (2002). In cold blood: Characteristics of criminal homicides as a function of psychopathy. In *Journal of Abnormal Psychology* (Vol. 111, Issue 3, pp. 436–445). American Psychological Association. <https://doi.org/10.1037/0021-843X.111.3.436>
- Woolfolk, A. E. (1999). *Psicología educativa* (séptima ed). Prentice Hall.
- Wortley, R., & Tilley, N. (2014). Theories for situational and environmental crime prevention. In *Encyclopedia of criminology and criminal justice* (G. Bruinsma, pp. 5164–5173). Springer New York.
- Yaksic, E. (2015). Addressing the challenges and limitations of utilizing data to study serial homicide. *Crime Psychology Review*, *1*(1), 108–134.
<https://doi.org/10.1080/23744006.2016.1168597>
- Yaksic, E. (2022). *Killer Data: Modern Perspectives on Serial Murder*. Routledge Studies in Criminal Behaviour.
- Yaksic, E., Allely, C., De Silva, R., Smith-Inglis, M., Konikoff, D., Ryan, K., Gordon, D., Denisov, E., & Keatley, D. A. (2019). Detecting a decline in serial homicide: Have we banished the devil from the details? *Cogent Social Sciences*, *5*(1), 1–23.
<https://doi.org/10.1080/23311886.2019.1678450>
- Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, *1168*(2). <https://doi.org/10.1088/1742-6596/1168/2/022022>
- Yokota, K., Kuraishi, H., Wachi, T., Otsuka, Y., Hiramata, K., & Watanabe, K. (2017). Practice of

offender profiling in Japan. *International Journal of Police Science & Management*, 19(3), 187–194. <https://doi.org/10.1177/1461355717714001>

Youngs, D. (2008). *Applications of Geographical Offender Profiling*. (D. Canter, Ed.) (1st ed.). Routledge. <https://doi.org/10.4324/9781315262338>

Yuill, R. S. (1971). The Standard Deviatonal Ellipse; An Updated Tool for Spatial Description. *Geografiska Annaler. Series B, Human Geography*, 53(1), 28–39. <https://doi.org/10.2307/490885>

Zar, J. (1999). *Biostatistical Analysis* (4th ed.). Prentice-Hall.

Zhu, K., & Zhang, J. (2012). *Predicting the potential locations of the next crime based on data mining : A case Study*. *Int. J. Digit. Content Technol. Its Appl* (6) 574-581. <https://doi.org/10.4156/jdcta.vol6.issue20.62>

Zipf, G. K. (1949). *Human behavior and the principle of least effort*. Addison-Wesley Press.

Zuur, A.F., Ieno, E.N., Walker, N., Savelief, A.A. y Smith, G. (2009). *Mixed Effects Models and Extensions in Ecology with R*. Springer. <https://doi.org/10.1016/j.baae.2009.06.001>

ANEXOS

ANEXO A DELINCUENTES DE HOMICIDIO EN SERIE (SHOs)

ANEXO A

Apellidos	Nombre	Nº Crimen	Fecha Inicial	Fecha Final	País
ARGUELLES	ROBERTO	4	2/21/1992	3/19/1992	ESTADOS UNIDOS
BIANCHI	KENNETH ALESSIO	8	10/18/1977	12/9/1977	ESTADOS UNIDOS
BILANCIA	DONATO	5	3/9/1998	4/12/1998	ITALIA
BIRNIE	DAVID JOHN	4	10/6/1986	11/5/1986	AUSTRALIA
BLACK	ROBERT	4	8/1/1981	3/26/1986	REINO UNIDO
BODEN	WAYNE CLIFFORD	4	10/3/1969	5/18/1971	CANADA
BRADY	IAN	5	11/23/1963	6/10/1965	REINO UNIDO
CARTER	DEAN PHILLIP	4	5/10/1984	5/14/1984	ESTADOS UNIDOS
CONDITT	MARK	6	3/2/2018	3/20/2018	ESTADOS UNIDOS
DAHMER	JEFFREY LIONEL	5	9/15/1987	4/23/1969	ESTADOS UNIDOS
DESALVO	ALBERT	13	6/14/1962	1/4/1964	ESTADOS UNIDOS
DUBE	SIPHO	6	3/23/2001	11/8/2003	S.AFRICA
DUTROUX	MARC	4	6/24/1995	8/9/1996	OTHER
DWAYNE	CRISTOPHER	7	10/30/1990	12/18/1990	ESTADOS UNIDOS
ERSKINE	KENNETH	6	4/9/1986	7/23/1986	REINO UNIDO
FARRINGTON	CORDELL	4	5/16/2003	9/28/2003	OTHER
FAYNE	LORENZO	6	9/15/1989	7/17/1994	ESTADOS UNIDOS
FERRANDIZ	JOAQUIN	6	2/7/1995	2/15/1998	ESPAÑA
FIGUEROA	DANNY	4	5/13/1986	8/6/1986	ESTADOS UNIDOS
FONTAIN	ROY	5	7/1/1977	1/14/1978	REINO UNIDO
FORD	WAYNE ADAM	4	6/2/1998	10/17/1988	ESTADOS UNIDOS

Apellidos	Nombre	Nº Crimen	Fecha Inicial	Fecha Final	País
FOURNIRET	MICHEL	8	12/11/1987	5/5/2001	FRANCIA
GALAN SOTILLO	ALFREDO	5	1/24/2003	5/2/2003	ESPAÑA
GAMPER	FERDINAND	4	2/8/1996	3/1/1996	ITALIA
GARCIA ESCALERO	FRANCISCO	11	7/30/1987	9/9/1993	ESPAÑA
GLOVER	JOHN	6	1/3/1989	3/19/1990	AUSTRALIA
GORE	DAVID ALAN	4	2/19/1981	7/26/1983	ESTADOS UNIDOS
GRANT	WALDO	4	9/14/1973	12/29/1976	ESTADOS UNIDOS
GRIEVESON	STEVEN	4	1/1/1990	2/25/1994	REINO UNIDO
HAIGH	JOHN GEORGE	4	9/9/1944	2/18/1949	REINO UNIDO
HAUSNER	DALE SHAWN	5	6/29/2005	7/30/2006	ESTADOS UNIDOS
IRELAND	COLIN	5	3/3/1993	6/15/1993	REINO UNIDO
IRVIN	LESLIE	4	12/2/1954	3/28/1955	ESTADOS UNIDOS
JAGTAP	SHANTARAM	5	1/16/1976	3/23/1977	INDIA
JOHNSON	CORY	8	1/4/1992	2/19/1992	ESTADOS UNIDOS
JOHNSON	VINCENT	6	6/22/1999	2/3/2000	ESTADOS UNIDOS
JORDAN	GILBERT PAUL	7	7/30/1982	11/26/1987	CANADA
KEMPER	EDMUND EMIL	6	8/27/1964	2/5/1973	ESTADOS UNIDOS
KIRKLAN	ANTHONY	4	3/1/2006	3/7/2009	ESTADOS UNIDOS
KNYCHAL	JOACHIM	5	1/11/1975	8/5/1982	POLONIA
KODAIRA	YOSHIO	9	5/25/1945	8/6/1946	JAPÓN
KROLL	JOACHIM GEORG	9	2/8/1955	7/3/1976	ALEMANIA
KURTEN	PETER	5	8/24/1929	12/2/1929	ALEMANIA
LEGEBOOKOFF	CODY	4	9/10/2009	11/27/2010	CANADA
LEGORRETA	CESAR ARMANDO LIBRADO	7	11/26/2010	7/13/2011	MEXICO
LONG	BOBBY JOE	9	5/13/1984	11/11/1984	ESTADOS UNIDOS
LOVGREN	JOHN INGVAR	4	6/27/1957	9/2/1963	SUECIA

Apellidos	Nombre	Nº Crimen	Fecha Inicial	Fecha Final	País
LUPO	MICHAEL	4	3/15/1986	4/24/1986	REINO UNIDO
MACDONALD	WILLIAM	5	2/2/1961	6/6/1962	AUSTRALIA
MACON	MATTHEW EMMANUEL	6	1/23/2005	8/29/2007	ESTADOS UNIDOS
MANUEL	PETER THOMAS ANTHONY	5	1/2/1956	12/31/1958	REINO UNIDO
MARCHWICKI	ZDZISLAW	9	11/7/1964	8/25/1965	POLONIA
MAZINGANE	LAZARUS TSHIDISO	16	4/13/1993	4/23/1998	S.AFRICA
MINGHELLA	MAURIZIO	5	4/18/1978	11/28/1978	ITALIA
MORRIS	RAYMOND LESLIE	4	9/8/1965	11/4/1968	REINO UNIDO
MYAZAKI	TSUTOMU	4	8/22/1988	11/3/1989	JAPÓN
NAKADA	PEDRO PABLO	13	1/1/2005	12/27/2006	OTHER
NEILSON	DONALD	4	2/15/1974	1/17/1975	REINO UNIDO
OCAMPO	ITZCOATL	4	12/20/2011	1/13/2012	ESTADOS UNIDOS
OLSON	CLIFFORD	11	11/19/1980	7/30/1981	CANADA
ORTIZ	ANTONIO	4	9/25/2013	8/22/2014	ESPAÑA
PACCIANI	PIETRO	5	6/6/1981	7/29/1984	ITALIA
PHUMPHUANG	SOMKHID	5	1/30/2005	6/21/2005	OTHER
PINTARIC	VINKO	5	4/26/1973	8/2/1990	OTHER
POEHLKE	NORBERT HANS	4	5/3/1984	10/20/1985	ALEMANIA
POYNER	SYVASKY LAFAYETTE	4	1/23/1984	2/2/1984	ESTADOS UNIDOS
PRICE	LARME	4	2/8/2003	3/20/2003	ESTADOS UNIDOS
PUTT	GEORGE HOWARD	4	8/14/1969	9/11/1969	ESTADOS UNIDOS
QUANSAH	CHARLES EBO	20	8/20/1998	6/22/1999	OTHER
RALSTON	LARRY	5	9/3/1975	6/30/1976	ESTADOS UNIDOS
RAMIREZ	RICHARD	15	6/28/1984	8/24/1985	ESTADOS UNIDOS
RAND	ANDRE	4	7/10/1972	7/9/1987	ESTADOS UNIDOS
RELDAN	ROBERT	5	8/10/1974	10/24/1975	ESTADOS UNIDOS

Apellidos	Nombre	Nº Crimen	Fecha Inicial	Fecha Final	País
RESENDIZ	ANGEL	6	8/29/1997	10/4/1998	ESTADOS UNIDOS
RIFKIN	JOEL	13	3/5/1989	6/14/1995	ESTADOS UNIDOS
RIVERA	REINALDO	4	7/17/1999	9/4/2000	ESTADOS UNIDOS
ROGERS	GLEN	4	9/1/1993	10/11/1993	ESTADOS UNIDOS
ROSS	MICHAEL BRUCE	7	5/12/1981	6/13/1984	ESTADOS UNIDOS
RUBEL	ALEXANDER	7	9/19/1997	7/4/1998	RUSIA
SANCHEZ	REMEDIOS	8	6/10/2006	7/3/2006	ESPAÑA
SAYENKO	VIKTOR	7	6/25/2007	7/12/2007	RUSIA
SCHMIDT	WOLFGANG	5	10/24/1989	4/5/1991	ALEMANIA
SEEL	MANFRED	5	6/14/1991	6/15/1998	ALEMANIA
SHAH	MUNAWAR HARUN	5	1/16/1976	3/23/1977	INDIA
SHULMAN	ROBERT YALE	5	8/1/1991	12/8/1995	ESTADOS UNIDOS
SINGH	DARBARA	11	4/18/2004	8/28/2004	INDIA
SMITH	MARK ALLEN	4	12/3/1969	5/27/1970	ESTADOS UNIDOS
SUTCLIFFE	PETER	20	7/5/1975	11/17/1980	REINO UNIDO
TABORSKY	JOSEPH	7	3/23/1950	1/26/1957	ESTADOS UNIDOS
TAYLOR	KEVIN	4	6/25/2001	8/18/2001	ESTADOS UNIDOS
TRENTON	RICHARD	4	12/29/1977	1/26/1978	ESTADOS UNIDOS
WEIDENBROEKER	HELMUT	5	5/4/1982	3/6/1986	ALEMANIA
WEST	ROSEMARY	8	8/1/1967	6/1/1987	REINO UNIDO
WILLIAMS	JOHN	6	1/7/1995	12/26/1995	ESTADOS UNIDOS
WILLIAMS	CARL ANTHONY	5	6/15/2000	3/31/2004	AUSTRALIA
WOLTER	MICHAEL	8	5/7/1980	11/26/1983	ALEMANIA
WORRELL	CHRISTOPHER ROBIN	7	12/23/1976	2/12/1977	AUSTRALIA
WRIGHT	STEVEN GERALD JAMES	5	10/30/2006	12/10/2006	REINO UNIDO
YATES	ROBERT LEE	11	7/14/1996	7/7/1998	ESTADOS UNIDOS



Cuestionario

Set Datos

Mod, C2_2015

IR Number	20180320-161610-1	Start	1/7/1995		SAT
Crime	SERIAL_1	End	1/7/1995		SAT
Location Type		Longitud			
Address	1500 BLOCK BLOUNET ST	Latitud			
Address Name	Patrida Ashe				
IR Number	20180320-161610-1	Start	1/12/1995		THU
Crime	SERIAL_2	End	1/12/1995		THU
Location Type		Longitud			
Address	1905 PAULE RALEIGH	Latitud			
Address Name					
IR Number	20180320-161610-1	Start	6/13/1995		TUE
Crime	SERIAL_3	End	6/13/1995		TUE
Location Type		Longitud			
Address	OS KOWOOD CEMETERY	Latitud			
Address Name					
IR Number	20180320-161610-1	Start	7/8/1995		SAT
Crime	SERIAL_4	End	7/8/1995		SAT
Location Type		Longitud			
Address	MORGAN ST	Latitud			
Address Name	Dawn Grandy				
IR Number	20180320-161610-1	Start	8/22/1995		TUE
Crime	SERIAL_5	End	8/22/1995		TUE
Location Type		Longitud			
Address	MC DOWELL ST AT MLK	Latitud			
Address Name	Cynthia Brown				
IR Number	20180320-161610-1	Start	12/26/1995		TUE
Crime	SERIAL_6	End	12/26/1995		TUE

User ID: 1

ANEXO C

INDICIO DE CALIDAD DE LA TESIS DOCTORAL

(ARTÍCULO CIENTÍFICO)



Humanos versus Algoritmos: Diferencias en la eficacia en el perfilado geográfico criminal

Humans versus Algorithms: Differences in Efficiency in Criminal Geographic Profiling

Daniel Salafranca Barreda  ^{1*}

¹Centro Crimina, Universidad Miguel Hernández

*La correspondencia debe dirigirse a: d.salafranca@crimina.es

Recibido febrero 2023 / Aceptado agosto 2023

Resumen

Los estudios que han explorado una variedad de tareas de predicción han demostrado que las heurísticas utilizadas por los individuos para simplificar problemas complejos pueden funcionar con la misma precisión que las técnicas actuariales. Con el objetivo de comprobar esta hipótesis, se llevó a cabo un experimento para investigar si las ventajas de la práctica humana en la elaboración de perfiles geográficos coinciden con las ventajas de utilizar algoritmos informáticos. Hasta el momento, en España no se han encontrado estudios que aborden el debate en curso sobre si las personas pueden ser igual de efectivas que las técnicas informáticas actuariales al tomar decisiones sobre la localización del domicilio de un delincuente en serie. La presente investigación, realizada en dos centros universitarios españoles, es la primera en abordar esta cuestión. Utilizando una muestra aleatoria de delincuentes en serie, los resultados indicaron que los participantes a los que se les presentó una heurística basada en la hipótesis del círculo y una estrategia de decaimiento de la distancia no mostraron una mejora significativa en la precisión de las predicciones, y su desempeño posterior al entrenamiento no difirió significativamente de las predicciones generadas por una técnica actuarial. Se discuten varias posibles explicaciones para las actuaciones precisas de los participantes y las implicaciones prácticas para la integración de habilidades cognitivas.

Palabras clave: Perfil geográfico, experimento Snook, algoritmo, mecanismos cognitivos, delincuente serial

Abstract

Studies exploring a number of different prediction tasks have shown that heuristics, used by individuals to reduce complex problems into simpler judgments, can perform as accurately as actuarial techniques. To test this hypothesis they conducted an experiment in the interest of testing whether the advantages of human practice in the task of geographic profiling coincide with the advantages of using computer algorithms. No studies have been found in Spain to answer the ongoing debate as to whether humans can be as effective as actuarial computer techniques when faced with decisions about the location of a serial offender's home. The present research is the

first conducted in two Spanish university centers for this purpose. Using a random sample of serial offenders, results indicated that participants presented with a circle hypothesis heuristic and a distance decay strategy showed no significant improvement in prediction accuracy, and that their post-training performance did not differ significantly from the predictions of an actuarial technique. Several possible explanations for the participants' accurate performances and practical implications for cognitive skill integration are discussed.

Keywords: Geographic profiling, Snook experiment, algorithm, cognitive mechanisms, serial offender

Introducción

En los últimos años, se han utilizado diversos algoritmos para predecir la ubicación del domicilio o punto de anclaje de asesinos seriales desconocidos, basándose en las ubicaciones de los crímenes que se han vinculado a un delincuente (Canter & Larkin, 1993; Rossmo, 1995). Estos métodos han evolucionado desde tipologías espaciales, como la distinción entre merodeadores y viajeros (Canter & Gregory, 1994), hasta herramientas de software especializadas en el perfil geográfico (enfoque actuarial). Hay tres programas informáticos de perfiles geográficos ampliamente utilizados que implementan estos modelos: RigelTM (Rossmo, 2000) se basa en el algoritmo CGT (*Criminal Geographic Targeting*), DragNet[®] (Canter et al., 2013) utiliza una función exponencial negativa, que asume que la probabilidad de encontrar el domicilio de un delincuente en serie disminuye exponencialmente a medida que aumenta la distancia desde su ubicación del crimen, y CrimeStat[®] (Levine, 2015) que permite al usuario seleccionar entre cinco funciones de disminución de distancia: lineal, exponencial negativa, normal, lognormal y exponencial negativa truncada. Cada programa utiliza algoritmos matemáticos y parámetros basados en investigaciones empíricas sobre el comportamiento de viaje de los delincuentes, tomando en cuenta la distribución de las distancias de viaje, y han determinado qué forma de función de disminución de distancia es la más adecuada.

A pesar de la popularidad de los sistemas de software basados en algoritmos matemáticos para la predicción del comportamiento delictivo (estrategia actuarial), persisten dudas sobre si estos sistemas son más precisos que la predicción realizada por humanos. Varios estudios (Bennell & Taylor et al., 2007; Paulsen, 2006; Snook et al., 2002; Taylor et al., 2009; van de Kemp et al., 2005) han demostrado que el desempeño humano en esta tarea es similar al de los algoritmos informáticos, puesto que el proceso subyacente se basa en una heurística simple en lugar de un conjunto complejo de cálculos. Los psicólogos han estado interesados durante mucho tiempo en comprender los mecanismos cognitivos que permiten a las personas encontrar soluciones efectivas a problemas complejos y mal definidos. En los últimos años, se ha prestado atención a cómo el sistema cognitivo aborda los desafíos que surgen en entornos naturalistas como las investigaciones criminales (Bennell, 2005; Crego & Alison, 2004).

Brent Snook (2000) presentó en el congreso de San Diego un análisis titulado "Utility or Futility? A provisional examination of the utility of a geographical decision support system", en el que se evaluaron las ventajas de los sistemas geográficos informatizados para predecir la ubicación de los agresores.

Aunque los resultados plantearon dudas sobre la necesidad de proporcionar a las organizaciones policiales herramientas de software de perfilado geográfico, destacaron la importancia de una formación adecuada en perfilado geográfico como una alternativa más eficiente.

Los investigadores llevaron a cabo un análisis de alternativas a los sistemas de perfiles geográficos y exploraron la posibilidad de formar a las personas para hacer predicciones precisas de los perfiles (Levine, 2004; Paulsen, 2004; Snook et al., 2004, 2005). Gran parte de esta investigación se ha centrado en el uso de reglas simples o heurísticas para predecir la ubicación de los delincuentes en serie. Conceptualmente, estos estudios se basan en una creciente cantidad de investigaciones que demuestran que las personas utilizan heurísticas cognitivas simples para tomar decisiones precisas en una variedad de áreas (Gigerenzer et al., 1999). En este contexto, la heurística se refiere a mecanismos cognitivos que permiten tomar decisiones rápidas y con poco esfuerzo mental. Es una forma rápida y eficiente de tomar decisiones cuando el tiempo es limitado y el pensamiento profundo es un lujo que no se puede permitir. Estas heurísticas pueden permitir la toma de decisiones, clasificaciones y predicciones inteligentes al emplear una racionalidad limitada (Todd & Gigerenzer, 2000).

También, en línea con investigaciones anteriores (Bennell & Taylor et al., 2007; Paulsen, 2006; Snook et al., 2004; Snook et al., 2005) se ha demostrado que muchas personas utilizan heurísticas simples o pueden ser entrenadas para utilizarlas, logrando predecir con precisión la ubicación del hogar de los delincuentes en serie. En otras palabras, la hipótesis plantea que si se les proporciona a las personas algunos principios básicos que les permitan comprender el comportamiento espacial del delincuente, podrán hacer predicciones tan precisas como las realizadas por los sistemas de perfilado geográfico.

Esta hipótesis es importante de probar porque, de ser confirmada, cuestionaría la sugerencia de Rossmo (2000) de que el uso de sistemas de perfiles geográficos para hacer predicciones geográficas requiere al menos tres años de experiencia en la investigación de crímenes interpersonales y un alto nivel de habilidades investigativas, requisitos de entrenamiento extensos que han sido cuestionados por Levine (Rich & Shively, 2005). Además, el respaldo a esta hipótesis también podría generar discusiones sobre la necesidad de que las fuerzas y cuerpos de seguridad, que tienen recursos y capacidades tecnológicas limitados, inviertan en sistemas de perfiles geográficos.

Aunque es poco probable que las técnicas actuariales garanticen decisiones perfectas, se argumenta con frecuencia que, en promedio, producirán decisiones mejores que el razonamiento humano (Swets et al., 2000). A diferencia de este, las técnicas actuariales pueden evitar problemas relacionados con las expectativas previas, el exceso de confianza, la recuperación de información y el procesamiento de información (Jacob et al., 1986; Kleinmuntz, 1990). La demostración de las deficiencias del juicio humano ha sido vista por muchos como una justificación para el desarrollo de técnicas actuariales. La hipótesis plantea que, en general, los seres humanos llegan a respuestas que consideran adecuadas para problemas complejos, pero obvian el hecho de que están respondiendo a un problema diferente (simplificado); es decir, hacen juicios que no son aquellos que intentaron hacer (Fonseca, 2016).

La Psicología cognitiva, por su parte, ha tratado de explicar el razonamiento heurístico humano de manera general, identificando sus procesos típicamente como estrategias o pautas para tomar

decisiones. Los experimentos realizados en Psicología cognitiva sobre el razonamiento humano han generado discusiones sobre cómo caracterizar de la mejor manera el razonamiento heurístico, lo cual tiene implicaciones en los diversos ámbitos donde se utiliza la noción de heurística. Uno de los campos en los que se ha empleado comúnmente la noción de heurística es en las matemáticas, donde suele identificarse como un “atajo del pensamiento” que permite llegar a una solución sin establecer una prueba demostrativa. En las ciencias computacionales también se habla frecuentemente de procesos o estrategias heurísticos en diferentes sentidos, aunque en general se entiende como un proceso o regla que permite alcanzar una solución práctica, aunque no necesariamente óptima (Romanycia & Pelletier, 1985). Por tanto, es importante aclarar las limitaciones en la aplicación de los modelos de perfilado geográfico.

Los estudios que han explorado una variedad de tareas de predicción han demostrado que las heurísticas, o los atajos cognitivos, utilizados por los individuos para simplificar problemas complejos en juicios más simples, pueden ser igual de precisos que las técnicas actuariales (Gigerenzer et al., 1999). Esto ocurre cuando la heurística es ambientalmente racional, es decir, cuando coincide con la estructura del entorno de tal manera que aprovecha los patrones generales y las tendencias del comportamiento (Martignon & Hoffrage, 1999). La estructura del entorno se refiere a la información de que una persona, animal o institución conoce sobre un entorno físico o social (MacLeod, 2001). Según investigaciones recientes, se espera que las personas tengan a su disposición heurísticas para hacer predicciones sobre la tarea de perfiles geográficos, y algunas de estas heurísticas serán ambientalmente racionales y proporcionarán predicciones tan precisas como las de una técnica actuarial.

Por lo tanto, como un primer examen de estos problemas, el presente estudio hipotetiza que las limitaciones en cuanto a la capacidad del razonamiento o juicio humano para estimar la ubicación del domicilio de los delincuentes seriales continuarán tanto antes como después de la formación, debido a factores y variables que afectan a esta capacidad.

Estudio actual

El experimento de Snook (2000) fue un trabajo exploratorio que involucró a un número limitado de participantes. No se investigó si los participantes utilizaban heurísticas adecuadas de forma inherente antes del entrenamiento, lo que dificultó el análisis de las diferencias individuales en sus estrategias. Los hallazgos del estudio sugirieron la necesidad de replicar y ampliar la investigación en este campo y este trabajo pretende ser una contribución al respecto

Es importante destacar que el diseño del estudio original presentaba tanto la heurística del decaimiento de la distancia como la hipótesis del círculo de forma simultánea. Esto generó confusión en los participantes, ya que el comportamiento de los delincuentes (merodeadores o viajeros) no se ajustaba a este patrón en todos los casos. Esta situación es comparable a la utilización de software de perfilado geográfico, ya que dicho software también carece de la capacidad de distinguir entre merodeadores y viajeros, y predice ambos tipos utilizando el mismo método.

El estudio que se presenta es una ampliación y réplica del experimento realizado por Snook et al., (2002). Se compararon dos grupos: uno que recibió instrucciones sobre una heurística simple que se sabe que influye positivamente en la precisión de las predicciones, y otro grupo que no

recibió entrenamiento. El diseño del experimento se basó en la misma estructura básica del estudio anterior. El objetivo de este estudio fue evaluar la capacidad de los participantes y determinar, desde una perspectiva estadística, en qué medida el enfoque heurístico puede generar predicciones tan precisas como los métodos actuariales.

Metodología

Participantes

El experimento se llevó a cabo en dos centros universitarios de la Comunidad Valenciana, España, en las fechas 11/11/2015 y 16/02/2016. Los participantes fueron 48 estudiantes, 32 hombres y 16 mujeres, pertenecientes al Grado de Ingeniería en Tecnologías Industriales¹ (UJI) y en el Grado de Derecho² (UMH). La edad de los estudiantes oscilaba entre los 18 y los 22 años y la duración de la sesión para cada grupo duró 20 minutos.

Material

A cada participante se le proporcionaron 15 mapas que representaban los lugares asociados a delincuentes seriales. Estos delincuentes incluían a Albert Desalvo, Richard Trenton, Richard Ramirez, Ian Brady y Myra, Jerry Brudos, Fred Rosemary West, Jeffrey Dahmer, David Berkowitz, Robert Lee Yates, Peter Sutcliffe, Steve Wright, Marc Dutroux, Michel Fournirets, Antonio Ortiz y Joaquín Ferrándiz.

En la muestra utilizada en el experimento, el 93 % de los delincuentes seriales se clasificaron como merodeadores. No obstante, es importante tener en cuenta que el 50 % de los merodeadores tienen su domicilio muy cerca del borde del círculo.

La clasificación entre merodeador o viajero a menudo se simplifica utilizando un único criterio geométrico: la hipótesis del círculo. Según este criterio, si la residencia del delincuente se encuentra dentro del círculo que conecta los dos delitos más lejanos, se le clasifica como merodeador; de lo contrario, se le considera un viajero. Sin embargo, este criterio depende en gran medida de la distancia entre los dos delitos más alejados y no representa una característica estable del perpetrador, sino más bien una indicación de su patrón de viaje criminal.

Procedimiento

Los dos grupos de estudiantes (UMH y UJI) participaron en todas las etapas del experimento en una sola sesión, llevada a cabo en las respectivas aulas de los centros universitarios. Se informó a los participantes que realizarían predicciones sobre la ubicación probable de 15 delincuentes en serie y se les aclaró que el experimento no estaba relacionado con el rendimiento de la memoria. Su participación fue totalmente voluntaria y libre, y se mantuvo la anonimidad de los estudiantes al llevar a cabo los ejercicios.

¹<https://www.uji.es/estudis/oferta/base/graus/actual/enginyeria-industrial/>

²https://www.umh.es/contenido/Estudios/tit_g_139_R2/datos_es.html

Para el experimento, se formaron dos grupos: experimental y control, cada uno compuesto por 24 estudiantes. La selección de los participantes se realizó de manera aleatoria y ninguno de ellos tenía conocimientos previos en Criminología o perfilado geográfico. A cada grupo se le entregaron 15 mapas que representaban la ubicación de una serie de crímenes cometidos por diferentes delincuentes seriales, con un mínimo de cuatro y un máximo de 20 delitos. Se les pidió a los participantes que marcaran con una (X) la ubicación donde creían que se encontraba el domicilio previsible de los delincuentes seriales.

Antes de que se les pidiera a los estudiantes del grupo experimental que realizaran nuevamente las predicciones, el grupo de control abandonó el aula durante 10 minutos. Durante ese tiempo, el grupo experimental recibió una formación básica, que consistió en informarles sobre dos heurísticas basadas en regularidades empíricas del comportamiento ambiental de los delincuentes en serie.

A los estudiantes se les explicó en un periodo de 10 minutos la primera heurística, llamada reducción de frecuencia de los hechos en relación con el aumento de la distancia del domicilio" (*distance decay*) (Rengert et al., 1999). También se les informó sobre la segunda heurística, conocida como "hipótesis del círculo de Canter", que indica que generalmente la residencia del delincuente se encuentra dentro del círculo cuyo diámetro está determinado por los dos hechos más lejanos entre sí (Canter & Larkin, 1993). Durante el transcurso del experimento (fase 1 y fase 2), se contó con la presencia de profesionales con experiencia en perfilado geográfico en el aula, quienes estuvieron disponibles para responder a cualquier duda y garantizar que el ejercicio se llevara a cabo de manera individual. La ejecución de los ejercicios se realizó aproximadamente en 15 minutos, tras lo cual los participantes recibieron una presentación sobre la técnica de perfilado geográfico, para complementar el conocimiento del grupo que no asistió a la primera sesión.

Predicciones actuariales

Dado que el objetivo de cualquier procedimiento de elaboración de perfiles geográficos es lograr predicciones precisas, exactas y eficientes (Bennell et al., 2009) en este estudio se ha seguido la línea de trabajo de Snook et al., (2005) al clasificar los algoritmos para el perfil geográfico en dos categorías basadas en su estrategia global. Se ha optado por utilizar una estrategia de distribución espacial y la estrategia de distancia de probabilidad utilizada en el primer experimento de Snook et al., (2002).

La precisión se refiere a la variabilidad en las predicciones realizadas para una serie de delitos cuando se utiliza un procedimiento de elaboración de perfiles en particular. Por otro lado, la eficiencia se refiere al esfuerzo que debe realizar la policía (por ejemplo, el área en la que deben buscar para encontrar las ubicaciones de los delincuentes) cuando se utiliza un procedimiento de elaboración de perfiles en particular. En este estudio, la eficiencia se ha operacionalizado previamente como el porcentaje de una superficie de riesgo (generada mediante algún procedimiento algorítmico) que debe ser buscada antes de localizar el punto de anclaje del infractor (Bennell et al., 2009). Sin embargo, debido a las limitaciones del experimento, no se pudo evaluar la eficiencia utilizando una estrategia de probabilidad adaptada a los participantes.

Todos los enfoques del perfil geográfico que utilizan una estrategia de distancia de probabilidad, junto con un método de decaimiento con la distancia, asignan pesos a la escena del crimen en función

de la distancia al centroide de cada celda. La probabilidad se calcula bajo el supuesto de que los delincuentes cometen delitos en las cercanías de su lugar de residencia. Los lugares de crímenes que están cercanos entre sí reciben más peso que los lugares más distantes.

La predicción de la residencia de un delincuente dentro de este espacio se logra aplicando una función matemática (Ecuación 1) alrededor de cada lugar del delito, generando una malla con un tamaño de celda o cuadrícula determinado sobre la distribución espacial de los incidentes delictivos (área de actuación). A cada celda se le asigna un peso en relación con la distancia (*network*, euclidiana y *Manhattan*) de los incidentes delictivos con respecto al centroide de cada celda. Finalmente, los valores de las celdas se calculan sumando los valores de cada incidente en función del algoritmo aplicado. El resultado es una superficie en la que los valores más altos en determinadas zonas indican la probabilidad de que un delincuente pueda vivir dentro de esa área, y la celda con la puntuación de probabilidad más alta determinará el punto de anclaje del delincuente.

Las estrategias de distancia de probabilidad difieren en la forma de la función matemática aplicada alrededor de cada lugar del delito y en los supuestos respecto a la relación entre la residencia de los delincuentes y el lugar donde cometen sus delitos.

Si bien los investigadores han desarrollado varias funciones diferentes para calcular el decaimiento con la distancia (Levine, 2015) en el primer experimento de Snook se obtuvieron las predicciones para cada uno de los mapas utilizando una función exponencial negativa (Canter et al., 2000) a través del programa *Dragnet*®. En el presente estudio, se utilizó el programa *Crime Stat*® y la misma función exponencial negativa. Esta función asume que la probabilidad de encontrar la residencia de un delincuente disminuye a medida que aumenta la distancia desde un delito, y se expresa mediante la siguiente ecuación:

$$f(d_{ij}) = A(e^{Bd_{ij}}) \quad (1)$$

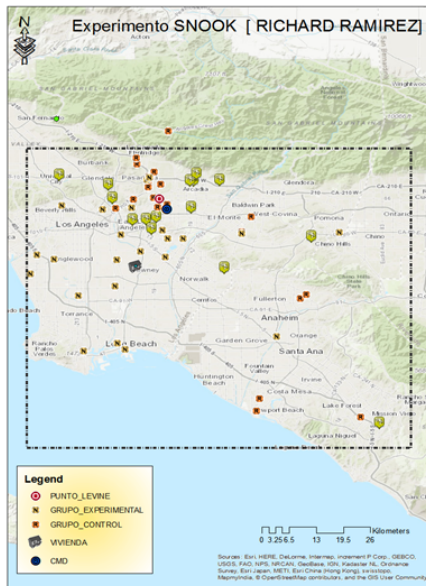
donde $f(d_{ij})$ es la probabilidad de que la residencia de un delincuente se ubique en un lugar determinado, d_{ij} es la distancia desde el centro de la celda de la cuadrícula (i) a un delito (j), A es un coeficiente arbitrario con un valor determinado (de 1.89) utilizado para proporcionar un indicación de la probabilidad de encontrar el domicilio, e es la base del logaritmo natural, y (B) es un exponente con un valor determinado (de -0.06) que determina el gradiente de la función (Levine & Associates, 2000) (Figura 2).

Esta función es muy similar al modelo *Dragnet*®, excepto que el coeficiente está matemáticamente calibrado para la distribución observada. Además de ser una función ampliamente utilizada para la elaboración de perfiles geográficos, también se ha demostrado que tiene un rendimiento comparable al de funciones más elaboradas (Paulsen, 2006; Snook et al., 2005).

Las predicciones utilizando la función exponencial negativa se generaron mediante la introducción de las coordenadas geográficas de longitud y latitud de cada ubicación del delito en el software *CrimeStat* (Levine & Associates, 2000). Para realizar el análisis de medición de distancias euclidianas entre todos los puntos marcados por los alumnos y los domicilios de los agresores, se utilizó el Sistema de Información Geográfica ArcGIS versión 10.5. Las distancias se midieron en grados y se representan en la Figura 1.

Figura 1

Geocodificación de los puntos marcados (Grupo Control / Experimental).



Elaboración propia

La segunda estrategia empleada en el experimento ha sido la de distribución espacial. Para ello, se utilizó el algoritmo del centro de mínima distancia (Figura 2), que determina el punto donde la distancia a todos los demás puntos es mínima. Este centro se considera el mejor predictor único de la ubicación del domicilio del delincuente (Levine, 2015). A su vez, Neldner (2015) recopila la opinión de otros autores sobre el centro de mínima distancia, resaltando que también es altamente preciso para revelar la ubicación de la base de operaciones de los delincuentes de tipo merodeador.

Medición de la agrupación de incidentes

Para evaluar la precisión de las predicciones de los estudiantes, se utilizó el índice del vecino más cercano (NNI), un método rápido y sencillo para verificar la existencia de agregación espacial o agrupamientos. Se considera que existe agregación si el valor del NNI es inferior a 1. Esta estadística de vecinos más cercanos permite comparar la distancia media observada entre un conjunto de puntos y sus vecinos más cercanos, con la distancia esperada si estuvieran distribuidos al azar (Rogerson, 2001).

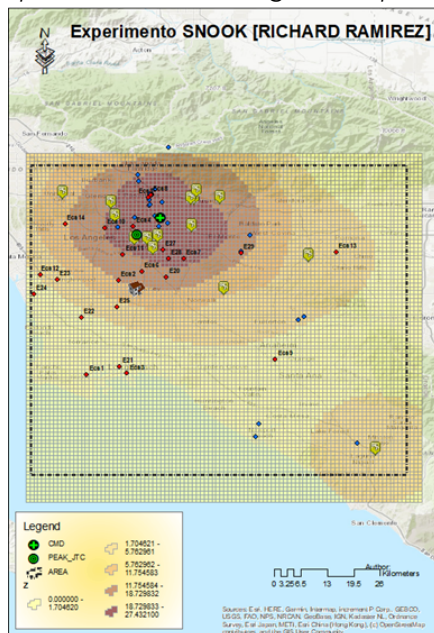
El NNI ofrece una aproximación de si los eventos criminales están más agrupados o dispersos de lo que se esperaría basándose en la aleatoriedad. Se compara la distancia promedio entre los puntos y sus vecinos más cercanos con la distancia esperada cuando se distribuyen de manera aleatoria. El resultado se obtiene dividiendo el promedio empírico de la distancia del vecino más cercano por la

distancia esperada.

La discrepancia en la dispersión entre el grupo experimental y el grupo de control puede indicar la existencia de agrupación espacial en las decisiones de cada estudiante, lo que a su vez refleja un mayor nivel de comprensión de la información recibida (es decir, mayor acuerdo entre los participantes en sus predicciones). Por otro lado, la exactitud se midió en grados, calculando la distancia en línea recta entre la ubicación prevista y la ubicación real (es decir, la distancia de error). Cuanto menor sea la distancia de error, mayor será la precisión de las predicciones.

Figura 2

Aplicación Función negativa exponencial y Centro de mínima distancia



Elaboración propia

Medición de la precisión predictiva

Siguiendo la metodología propuesta por [Snook et al., \(2002\)](#) y la de [Bennell & Snook et al., \(2007\)](#) para evaluar en términos estadísticos en qué medida se puede determinar las predicciones realizadas por un enfoque de heurística simple y un método actuarial de perfil geográfico, se analizaron las siguientes medidas:

1. Se calcularon los coeficientes de correlación de Pearson (r) entre los grupos experimentales para medir la distancia de error (es decir, la distancia entre la ubicación del domicilio estimado y real).

2. Las magnitudes del tamaño del efecto (ES) se evaluaron mediante el examen de los valores r medios y sus respectivos intervalos de confianza (IC) del 95 %; para cada resultado se calcularon diferentes índices de tamaño del efecto. Para tamaños de muestra muy pequeños ($n < 20$) la g de Hedges se considera menos sesgada que la d de Cohen.

3. Los resultados también se evaluaron mediante la visualización del tamaño del efecto binomial de Rosenthal y Rubin (1982). Presentación binomial del tamaño del efecto (BESD, en su acepción en inglés: *Binomial Effect Size Display*). Esta estadística permite examinar los cambios en las tasas de

éxito que son atribuibles a la variable predictora, asumiendo una tasa base del 50 %. (Para ilustrar cómo se pueden interpretar las BESD en el contexto actual, un valor de $r = -.30$ se traduciría en una diferencia del 30 % en la capacidad predictiva entre los grupos experimentales —por ejemplo, predicciones humanas, 65 %— y de comparación, por ejemplo, sistemas actuariales, 35 %).

4. Resultados de contraste de medias (t de Student)

Resultados

En cuanto a la medición de la agrupación de incidentes, los valores medios del índice del vecino más cercano para el grupo de control en la primera fase son de 0,76 (desviación típica de 0,21), mientras que para el grupo experimental son de 0,94 (desviación típica de 0,18). En la segunda fase, los valores medios para el grupo de control son de 1,03 (desviación típica de 0,10), y para el grupo experimental son de 0,87 (desviación típica de 0,24).

En relación con la medición de la precisión predictiva:

(1) La distancia media de error en las cinco primeras series para el grupo de control en la primera fase fue de 0,185^º, mientras que para el grupo experimental fue de 0,176^º. *T-test* confirma que no hay una diferencia significativa entre las dos fases ($t=0,041$, $p=0,96$), con un coeficiente de correlación de Pearson de 0,891 ($t=3,40$, $p=0,04$). El BESD muestra un valor de $r=0,013$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,51, límite superior 0,53). El tamaño del efecto (Hedge's) es de 0,02, con un intervalo de confianza (CI) de -1,10 (límite inferior) y 1,14 (límite superior). En términos del BESD, la tasa de precisión para el grupo de control fue del 50,65 %, en comparación con el 49,35 % para el grupo experimental.

(2) La distancia media de error en las cinco primeras series para el grupo de control en la primera fase fue de 0,185^º, mientras que para la función exponencial negativa fue de 0,108^º. *T-test* confirma que no hay una diferencia significativa entre las dos fases ($t=0,041$, $p=0,96$), con un coeficiente de correlación de Pearson de 0,625 ($t=1,38$, $p=0,259$). El BESD muestra un valor de $r=0,32$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,29, límite superior 0,69). El tamaño del efecto (Hedge's g) es de 0,61, con un intervalo de confianza (CI) de -0,56 (límite inferior) y 1,75 (límite superior). En términos del BESD, la tasa de precisión para el grupo de control es un 32 % más efectiva que la función exponencial negativa.

(3) La distancia media de error en las cinco primeras series para el grupo experimental en la fase 1 fue de 0,175^º, mientras que para la función exponencial negativa fue de 0,108^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=0,99$, $p=0,357$), con un coeficiente de correlación de Pearson de 0,438 ($t=0,84$, $p=0,459$). El BESD muestra un valor de $r=0,29$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,31, límite superior 0,68). El tamaño del efecto (Hedge's g) es de 0,57, con un intervalo de confianza (CI) de -0,60 (límite inferior) y 1,70 (límite superior). En términos del BESD, la tasa de precisión del grupo experimental es un 29 % más efectiva que la función exponencial negativa.

(4) La distancia media de error en las cinco primeras series para el grupo experimental en la fase 1 fue de 0,175^º, mientras que para el centro de mínima distancia fue de 0,111^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=0,99$, $p=0,358$), con un coeficiente de

correlación de Pearson de 0,527 ($t=1,07$, $p=0,36$). El BESD muestra un valor de $r=0,29$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,31, límite superior 0,68). El tamaño del efecto (Hedge's g) es de 0,57, con un intervalo de confianza (CI) de -0,60 (límite inferior) y 1,70 (límite superior). En términos del BESD, la tasa de precisión del grupo de control es un 29 % más efectiva que el centro de mínima distancia.

(5) La distancia media de error en las cinco primeras series para la función exponencial negativa en la fase 1 fue de 0,108^º, mientras que para el centro de mínima distancia fue de 0,111^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=-0,018$, $p=0,98$), con un coeficiente de correlación de Pearson de 0,962 ($t=6,13$, $p=0,008$). El BESD muestra un valor de $r=-0,005$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,53, límite superior 0,52). El tamaño del efecto (Hedge's g) es de -0,01, con un intervalo de confianza (CI) de -1,13 (límite inferior) y 1,11 (límite superior). En términos del BESD, la tasa de precisión de la función exponencial fue del 49,75 %, en comparación con el 50,25 % para el centro de mínima distancia.

(6) La distancia media de error en las diez series para el grupo de control en la fase 2 fue de 0,457^º, mientras que para el grupo experimental fue de 0,208^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=-0,049$, $p=0,96$), con un coeficiente de correlación de Pearson de 0,996 ($t=31,67$, $p=1,075e-09$). El BESD muestra un valor de $r=-0,011$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,40, límite superior 0,39). El tamaño del efecto (Hedge's g) es de -0,02, con un intervalo de confianza (CI) de -0,86 (límite inferior) y 0,82 (límite superior). En términos del BESD, la tasa de precisión del grupo de control fue del 48,65 %, en comparación con el 52,45 % para el grupo experimental.

(7) La distancia media de error en las diez series para el grupo de control en la fase 2 fue de 0,457^º, mientras que para la función de decaimiento fue de 0,208^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=0,84$, $p=0,41$), con un coeficiente de correlación de Pearson de 0,316 ($t=0,943$, $p=0,37$). El BESD muestra un valor de $r=0,18$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,24, límite superior 0,53). El tamaño del efecto (Hedge's g) es de 0,36, con un intervalo de confianza (CI) de -0,49 (límite inferior) y 1,20 (límite superior). En términos del BESD, la tasa de precisión del grupo de control logra un 18 % más de eficacia que la función de decaimiento.

(8) La distancia media de error en las diez series para el grupo de control en la fase 2 fue de 0,457^º, mientras que para el centro de mínima distancia fue de 0,147^º. *T-test* confirma que no existe una diferencia significativa entre las dos fases ($t=1,09$, $p=0,29$), con un coeficiente de correlación de Pearson de 0,82 ($t=4,10$, $p=0,003$). El BESD muestra un valor de $r=0,23$, con un intervalo de confianza (CI) de 0,42 (límite inferior -0,19, límite superior 0,56). El tamaño del efecto (Hedge's g) es de 0,47, con un intervalo de confianza (CI) de -0,39 (límite inferior) y 1,32 (límite superior). En términos del BESD, la tasa de precisión del grupo de control logra un 23 % más de eficacia que el centro de mínima distancia.

(9) En la fase 2, la distancia media de error en las 10 series para el grupo experimental fue de 0,474^º, mientras que en la función de decaimiento fue de 0,208^º. *T-test* confirma que no hay una diferencia significativa entre las dos fases ($t=0,80$, $p=0,43$). El coeficiente de correlación de Pearson fue de 0,23 ($t=0,67$, $p=0,516$). En términos del BESD, se encontró una correlación de $r=0,17$, con un intervalo de confianza (CI) entre -0,25 y 0,52. El tamaño del efecto (Hedge's g) fue de 0,34, con un CI inferior de -0,51 y un CI superior de 1,19. En comparación con la función de decaimiento, la tasa de

precisión del grupo experimental fue un 17 % más efectiva.

(10) En la fase 2, la distancia media de error en las 10 series para el grupo experimental fue de 0.474^o, mientras que en el centro de mínima distancia fue de 0.147^o. *T-test* confirma que no hay una diferencia significativa entre las dos fases ($t= 1.01$, $p= 0.33$). El coeficiente de correlación de Pearson fue de 0.77 ($t=3.45$, $p=0.008$). En términos del BESD, se encontró una correlación de $r= 0.22$, con un intervalo de confianza (CI) entre -0.21 y 0.55. El tamaño del efecto (Hedge's g) fue de 0.44, con un CI inferior de -0.42 y un CI superior de 1.28. En comparación con el centro de mínima distancia, la tasa de precisión del grupo experimental fue un 22 % más efectiva.

(11) En la fase 2, la distancia media de error en las 10 series para la función de decaimiento fue de 0.208^o, mientras que en el centro de mínima distancia fue de 0.147^o. *T-test* confirma que no hay una diferencia significativa entre las dos fases ($t= 0.50$, $p= 0.62$). El coeficiente de correlación de Pearson fue de 0.76 ($t=3.36$, $p=0.009$). En términos del BESD, se encontró una correlación de $r= 0.11$, con un intervalo de confianza (CI) entre -0.31 y 0.48. El tamaño del efecto (Hedge's g) fue de 0.21, con un CI inferior de -0.63 y un CI superior de 1.05. En comparación con el centro de mínima distancia, la tasa de precisión de la función de decaimiento fue un 11 % más efectiva.

Tabla 1

Distancias de error medias para cada visualización espacial (mapa) para el grupo de control y el grupo experimental en las dos fases y función exponencial y centro mínima distancia (CMD).

Mapa	Grupo Control		Grupo Experimental		Función	CMD
	Fase 1 (n=24)	Fase 2	Fase 1 (n=24)	Fase 2		
1	0.067470		0.094660		0.075857	0.069441
2	0.038227		0.046582		0.013523	0.016264
3	0.250438		0.174688		0.120056	0.145033
4	0.167845		0.137353		0.184303	0.162414
5	0.283311		0.339627		0.114217	0.118390
6		0.114740		0.161512	0.012036	0.004114
7		0.046315		0.058467	0.007038	0.000000
8		2.691380		3.106628	0.264795	0.446947
9		0.708133		0.548060	1.058507	0.406726
10		0.140250		0.113529	0.174544	0.156895
11		0.136280		0.108462	0.051030	0.062400
12		0.253800		0.219477	0.126200	0.073113
13		0.071270		0.046089	0.119082	0.108834
14		0.025677		0.021557	0.030431	0.027768
15		0.040472		0.041937	0.043421	0.035928

Conclusiones y Discusión

En este estudio, se analizó el efecto del entrenamiento heurístico en la capacidad de los participantes para realizar predicciones en la elaboración de perfiles geográficos. Los resultados mostraron que la mayoría de los estudiantes no pudieron implementar la heurística de decaimiento después de recibir instrucciones breves. Además, se observó una escasa agrupación espacial en la toma de decisiones de los participantes del grupo experimental, lo que indica una menor comprensión de la información recibida.

Además, el estudio llegó a una conclusión relevante independientemente de la cantidad

de instrucciones o capacitación proporcionada, los participantes no pueden alcanzar el mismo nivel de precisión que se logra mediante un procedimiento algorítmico en la elaboración de perfiles geográficos. Los procedimientos algorítmicos garantizan la consistencia y repetibilidad de las predicciones, mientras que el juicio humano puede estar sujeto a limitaciones cognitivas y variaciones individuales en las estrategias utilizadas. Sin embargo, es importante tener en cuenta que diferentes heurísticas pueden tener un impacto variable en la elaboración de perfiles geográficos, y se requiere una mayor investigación para determinar cuál es la heurística óptima en este contexto.

Además, se ha observado que el procesamiento cognitivo humano puede verse sobrecargado al enfrentarse a una gran cantidad de información en la elaboración de perfiles geográficos. A medida que se incrementa la cantidad de información, es posible que el desempeño heurístico se vea afectado y no mejore de manera proporcional. Esto plantea interrogantes sobre la efectividad del enfoque heurístico en situaciones con una gran cantidad de datos.

Es importante tener en cuenta estos hallazgos al tomar decisiones sobre qué enfoque utilizar en la elaboración de perfiles geográficos. Si bien el juicio humano puede aportar intuiciones valiosas y adaptabilidad, los métodos algorítmicos ofrecen una mayor consistencia y capacidad para lidiar con grandes cantidades de información. La replicación y ampliación de este estudio son necesarias para obtener una comprensión más completa de las capacidades y limitaciones de los enfoques heurísticos y actuariales en la elaboración de perfiles geográficos.

Se observó que el número de lugares delictivos utilizados en la elaboración de perfiles geográficos es un factor importante que influye en la precisión de las predicciones. A medida que aumenta la cantidad de datos disponibles, se obtiene una mayor precisión en la elaboración de perfiles. Por otro lado, las series de delitos con menos de cinco casos pueden explicar por qué el rendimiento humano es comparable a los métodos basados en algoritmos en ciertos casos y se debe tener en cuenta que la elaboración de perfiles geográficos solo es apropiada en casos de delincuentes merodeadores o locales.

La capacidad limitada del sistema cognitivo humano puede resultar en un procesamiento sobrecargado cuando se enfrenta a una gran cantidad de información en la elaboración de perfiles geográficos. Esto plantea interrogantes sobre si el desempeño heurístico mejora o empeora a medida que se incrementa la cantidad de información disponible.

En conclusión, este estudio proporciona evidencia de que la implementación de heurísticas puede mejorar la precisión de las predicciones en la elaboración de perfiles geográficos. Sin embargo, los resultados también destacan las limitaciones del enfoque heurístico en comparación con los procedimientos algorítmicos, que se mostraron más confiables y consistentes.

Es importante tener en cuenta la comprensión de las heurísticas y la cantidad de información disponible al utilizar perfiles geográficos en investigaciones criminales. Además, se observó que la capacitación y las instrucciones no fueron suficientes para que los participantes alcanzaran el nivel de precisión de los métodos algorítmicos.

La medición de la agrupación de incidentes reveló una escasa agrupación espacial en las decisiones del grupo experimental, lo que indica una menor comprensión de la información y una falta de acuerdo entre los participantes en sus predicciones.

Aunque se observó una mejora en la precisión de las predicciones al proporcionar a los participantes información sobre heurísticas simples, es importante considerar que diferentes heurísticas pueden tener diferentes niveles de precisión. Además, no se determinó si la heurística de decaimiento de distancia de Levine es la más adecuada para la predicción de perfiles geográficos en casos de delincuentes seriales viajeros.

Es importante tener en cuenta que el razonamiento humano aplicado al perfilado no puede ser calibrado de la misma manera que los sistemas de software, lo cual puede limitar su precisión. Se requiere una evaluación cuidadosa de los resultados y las limitaciones de ambos enfoques al tomar decisiones en investigaciones criminales.

En general, estos hallazgos resaltan la importancia de considerar tanto los aspectos cognitivos como los algorítmicos en la elaboración de perfiles geográficos y la necesidad de seguir investigando y explorando diferentes enfoques y heurísticas para mejorar la precisión en este campo.

En conclusión, los resultados sugieren que la formación en heurísticas tiene un efecto moderado en la capacidad de las personas para predecir la ubicación de los hogares de los delincuentes en comparación con los métodos actuariales. Sin embargo, se observó que diferentes proporciones de delincuentes merodeadores y viajeros en los mapas pueden influir en los resultados. Además, el número de lugares delictivos utilizados en la elaboración de perfiles geográficos es un factor importante, y se necesita un mínimo de cinco ubicaciones para obtener patrones estables y un enfoque investigativo adecuado.

Limitaciones

Existen varias razones para ser cautelosos al interpretar e integrar los resultados de este estudio en nuestra comprensión del desempeño en la elaboración de perfiles geográficos.

En primer lugar, es posible que los resultados se deban, en parte, a los diferentes métodos de medición utilizados para evaluar el desempeño de los grupos participantes y los procedimientos algorítmicos. Es importante tener en cuenta que los participantes realizaron sus predicciones en copias de mapas y todas las mediciones fueron realizadas manualmente por uno de los autores, mientras que las medidas para los procedimientos algorítmicos se obtuvieron a través de un sistema automatizado. Aunque se tomó gran cuidado en la determinación de las medidas para nuestro grupo de participantes y muchas de las mediciones se verificaron dos veces, las medidas tomadas en grados utilizando coordenadas geográficas (longitud, latitud) no pueden ser tan precisas como aquellas generadas al proyectar las coordenadas en un sistema de coordenadas UTM (Universal Transverse Mercator) y utilizar metros como medida de distancia.

En segundo lugar, es importante tener en cuenta la naturaleza limitada de las instrucciones proporcionadas a los participantes. Estos no recibieron la misma información utilizada por muchos de los procedimientos algorítmicos (por ejemplo, las ubicaciones de origen de otros delincuentes). Aunque parece poco probable, dado que estos estudiantes no pudieron superar ni siquiera los algoritmos más básicos en el estudio actual, es posible que los participantes también puedan aprovechar esta información para ajustar sus propias predicciones. Relacionado con esto está la posibilidad de que existan otras heurísticas, más allá de la simple heurística de decaimiento con la

distancia examinada aquí, que podrían llevar a un mejor desempeño, y que otros participantes (por ejemplo, personal de la policía) estén mejor preparados para implementar heurísticas de elaboración de perfiles.

Un tercer punto a considerar está relacionado con los datos seleccionados, lo cual podría ser un factor de confusión en el estudio al utilizar únicamente una tipología delictiva (merodeadores), que es más propicia para la elaboración de perfiles geográficos (Rossmo, 2000, 2005b; Snook et al., 2005). Solo algunos de los estudios mencionan si las series de delitos utilizadas se seleccionaron al azar o mediante algún otro método. Además, Levine (2002) afirma que su selección de datos no fue aleatoria, sino que “se eligió para producir un equilibrio en el número de incidentes cometidos por cada individuo y para aproximar la distribución de incidentes por delincuentes en serie”, lo que podría haber ampliado la brecha en precisión entre los estudiantes en el grupo experimental y algunos de los procedimientos algorítmicos.

En cuarto lugar, es importante destacar que la precisión se midió únicamente mediante la distancia de error, ya que esta era la única medida que se podía utilizar para evaluar el método humano al proporcionar una predicción en un solo punto. Esta medida puede no ser la más apropiada para evaluar la precisión (Rich & Shively, 2005), especialmente cuando se examinan técnicas que pueden producir superficies de probabilidad (Rossmo, 2005a). Además, la elección de la medida de precisión puede influir en qué método parece más preciso (Paulsen, 2006). Esta situación ha llevado a varios investigadores a argumentar que las comparaciones basadas en la distancia de error ocultan injustamente la efectividad del método actuarial (Rich & Shively, 2005; Rossmo, 2005a). Sin embargo, al comparar los métodos actuariales con las predicciones humanas, se asume que las personas se limitan a predecir una única ubicación de máxima probabilidad. Del mismo modo que la medida de precisión con la distancia de error enmascara el rendimiento de los métodos actuariales, la comparación de las predicciones “X” con las estrategias de búsqueda oculta la posibilidad de que las personas puedan utilizar la heurística para proporcionar un área de búsqueda precisa. Es por esto que se optó por agregar otra estrategia de elaboración de perfiles (centro de mínima distancia) en la cual se pudiera realizar una predicción en un solo punto, como lo hace el método humano.

Dadas estas preocupaciones, es necesario tener cuidado al interpretar los resultados de este estudio hasta que se realice un examen más exhaustivo que compare a delincuentes seriales viajeros y merodeadores. Además, se debe tener en cuenta que, en las series utilizadas en este estudio, aproximadamente el 50 % de los casos correspondían a delincuentes cercanos a viajeros, lo cual podría haber afectado sustancialmente la precisión de los algoritmos utilizados. En este sentido, también sería útil en futuros estudios ampliar el conjunto de instrucciones proporcionadas a los estudiantes y llevar a cabo el experimento en escuelas de formación para las fuerzas y cuerpos de seguridad. Con el objetivo de integrar los métodos de razonamiento humano en la elaboración de perfiles geográficos, se han propuesto equipos multidisciplinarios en procesos analítico jerárquico (AHP), los cuales resultan especialmente útiles en situaciones que requieren considerar numerosos y diferentes tipos de criterios o muchas posibles alternativas (Maldonado & Salafranca, 2019).

Referencias bibliográficas

- Bennell, C. (2005). Improving police decision making: General principles and practical applications of receiver operating characteristic analysis. *Applied Cognitive Psychology*, 19, 1157–1175. <https://doi.org/10.1002/acp.1152>
- Bennell, C., Emeno, K., Snook, B., Taylor, P. J., & Goodwill, A. (2009). The precision, accuracy and efficiency of geographic profiling predictions: a simple heuristic versus mathematical algorithms. *Crime Mapping: A Journal of Research and Practice*, 1(2), 65–84.
- Bennell, C., Snook, B., Taylor, P. J., Corey, S., & Keyton, J. (2007). It's no Riddle, Choose the Middle: The Effect of Number of Crimes and Topographical Detail on Police Officer Predictions of Serial Burglars' Home Locations. *Criminal Justice and Behavior*, 34(1), 119–132. <https://doi.org/10.1177/0093854806290161>
- Bennell, C., Taylor, P. J., & Snook, B. (2007). Clinical versus Actuarial Geographic Profiling Strategies: A Review of the Research. *Police Practice and Research*, 8(4), 335–345. <https://doi.org/10.1080/15614260701615037>
- Canter, D., Coffey, T., Huntley, M., & Missen, C. (2000). Predicting Serial Killers' Home Base Using a Decision Support System. *Journal of Quantitative Criminology*, 16(4), 457–478. <https://doi.org/10.1023/A:1007551316253>
- Canter, D., Hammond, L., & Juszcak, P. (2013). *The Efficacy of Ideographic Models for Geographical Offender Profiling*. 29(3), 423–446. <https://doi.org/10.1007/s10940-012-9186-6>
- Canter, & Larkin, P. (1993). The environmental range of serial rapists. *Journal of Environmental Psychology*, 13(1), 63–69. [https://doi.org/10.1016/S0272-4944\(05\)80215-4](https://doi.org/10.1016/S0272-4944(05)80215-4)
- Canter, D. V., & Gregory, A. (1994). Identifying the residential location of rapists. *Journal of the Forensic Science Society*, 34(3), 169–175. [https://doi.org/10.1016/S0015-7368\(94\)72910-8](https://doi.org/10.1016/S0015-7368(94)72910-8)
- Crego, J., & Alison, L. (2004). Control and legacy as functions of perceived criticality in major incidents. *Journal of Investigative Psychology & Offender Profiling*, 207–225.
- Fonseca, A. L. (2016). El debate sobre las heurísticas. Una disputa sobre los criterios de buen razonamiento entre la Tradición de Heurística y Sesgo y la Racionalidad Ecológica. *Revista Valenciana, Estudios de Filosofía y Letras*, 17, 87. <https://doi.org/10.15174/rv.v0i17.178>
- Gigerenzer, G., Todd, P. M., & Group, A. R. (1999). *Simple heuristics that make us smart*. Oxford University Press.
- Jacob, V. S., Gaultney, L. D., & Salvendy, G. (1986). Strategies and biases in human decision-making and their implications for expert systems. *Behaviour & Information Technology*, 5, 119–140.
- Kleinmuntz, B. (1990). Why we still use our heads instead of formulas: toward an integrative approach. *Psychological Bulletin*, 107, 296–310.
- Levine, N. (2002). *Crimestat: A Spatial Statistics Program for the Analysis of Crime Incident Locations (v2.0)*. Ned Levine and Associates and the National Institute of Justice. www.icpsr.umich.edu/NACJD/crimestat.html
- Levine, N. (2004). *CrimeStat Documentation. A Spatial Statistics Program for the Analysis of Crime Incident Locations (3.0)*. <http://www.icpsr.umich.edu/CrimeStat/download.html>
- Levine, N. (2015). *CrimeStat: Spatial Statistics Program for the Analysis of Crime Incident Locations (v 4.02)*. Ned Levine & Associates, Houston, Texas, and the National Institute of Justice, Washington, D.C. August.
- MacLeod, W. (2001). Complexity, Bounded Rationality and Heuristic Search. *Contributions in Economic Analysis & Policy*, 1(1), 1538–0645.1059. <https://doi.org/10.2202/1538-0645.1059>
- Maldonado, D., & Salafranca, D. (2019). Propuesta metodológica para predecir el próximo lugar de actuación de un pederasta en serie. *International E-Journal of Criminal Science*, 14(2019), 1–12.
- Martignon, L., & Hoffrage, U. (1999). Why does one-reason decision making work? A case study in ecological

- rationality. In G. Gigerenzer, P. M. Todd, & The ABC Research Group, *Simple heuristics that make us smart* (pp. 119-140). Oxford University Press.
- Ned Levine & Associates. (2000). *Crimestat: A spatial statistics program for the analysis of crime incident locations* (version 1.1).
- Neldner R. (2015). *Geographic profiling of serial murderer, Gary Ridgway, to assist law enforcement in the apprehension of future serial murderers*. Saint Mary's University of Minnesota University Central Services Press.
- Paulsen, D. (2004). Geographic profiling hype or hope? *Preliminary results into the accuracy of geographic profiling software*. UK Crime Mapping Conference, London, UK.
- Paulsen, D. (2006). Human versus machine: a comparison of the accuracy of geographic profiling methods. *Journal of Investigative Psychology and Offender Profiling*, 3(2), 77-89. <https://doi.org/10.1002/jip.46>
- Rengert, G. F., Piquero, A. R., & Jones, P. R. (1999). Distance decay reexamined. *Criminology*, 37(2), 427-446. <https://doi.org/https://doi.org/10.1111/j.1745-9125.1999.tb00492.x>
- Rich, T., & Shively, M. (2005). *A Methodology for Evaluating Geographic Profiling Software*. 1-259. <https://www.ojp.gov/pdffiles1/nij/grants/208993.pdf>
- Rogerson, P. A. (2001). Monitoring point patterns for the development of space-time clusters. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 164(1), 87-96. <https://doi.org/10.1111/1467-985X.00188>
- Romanycia, M. H. J., & Pelletier, F. J. (1985). What is a heuristic? *Computational Intelligence*, 1(1), 47-58. <https://doi.org/10.1111/j.1467-8640.1985.tb00058.x>
- Rossmo D. K. (1995). *Geographic profiling: Target patterns of serial murderers* (Doctoral dissertation, Simon Fraser University). <http://summit.sfu.ca/item/6820>
- Rossmo, D.K. (2000). *Geographic Profiling*. CRC-Press.
- Rossmo D.K. (2005a). An evaluation of NIJ's evaluation methodology for geographic profiling software, 17. Recuperado de: https://www.researchgate.net/publication/288871418_Geographic_profiling_survey_A_preliminary_examination_of_geographic_profilers_views_and_experiences
- Rossmo, D.K. (2005b). Geographic heuristics or shortcuts to failure?: response to Snook et al. *Applied Cognitive Psychology*, 19(5), 651-654. <https://doi.org/10.1002/acp.1144>
- Snook, B. (diciembre,2000). *Utility or futility? A provisional examination of the utility of a geographical decision support tool*. [Presentación de paper] 4ª Conferencia Internacional de Investigación sobre Cartografía de la Delincuencia, San Diego, CA, USA.
- Snook, Brent, Canter, D., & Bennell, C. (2002). Predicting the home location of serial offenders: a preliminary comparison of the accuracy of human judges with a geographic profiling system. *Behavioral Sciences & the Law*, 20(1-2), 109-118. <https://doi.org/10.1002/bsl.474>
- Snook, Brent, Taylor, P. J., & Bennell, C. (2004). Geographic profiling: the fast, frugal, and accurate way. *Applied Cognitive Psychology*, 18(1), 105-121. <https://doi.org/10.1002/acp.956>
- Snook, Brent, Zito, M., Bennell, C., & Taylor, P. J. (2005). On the complexity and accuracy of geographic profiling strategies. *Journal of Quantitative Criminology*, 21(1), 1-25. <https://doi.org/10.1007/s10940-004-1785-4>
- Swets, J. A., Dawes, R. M., & Monahan, J. (2000). Psychological Science Can Improve Diagnostic Decisions. *Psychological Science in the Public Interest*, 1, 1-26.
- Taylor, P.J., Bennell, C. and Snook, B. (2009), The bounds of cognitive heuristic performance on the geographic profiling task. *Appl. Cognit. Psychol.*, 23: 410-430. <https://doi.org/10.1002/acp.1469>
- Todd, P. M., & Gigerenzer, G. (2000). Précis of Simple heuristics that make us smart. *Behavioral and Brain*

Sciences, 23(5), 727-780. <https://doi.org/10.1017/S0140525X00003447>

van de Kemp, J., van Ruth, E., Blokland, A., & Snook, B. (julio, 2005). "X" marks the spot: Comparing police officers, students, and geographical profiling software on the accuracy of their predictions. [Presentación de poster] XV Congreso Europeo de Psicología y Derecho, Vilnius, Lituania.

Autor

Daniel Salafranca Barreda, es Doctorando en Criminología en la Universidad Miguel Hernández, Máster en Sociología y Antropología de las Políticas Públicas (UV), profesor colaborador en el centro Crímina y miembro del grupo de Investigación en Homicidios Atípicos. Sus líneas de investigación son el perfil geográfico y los mapas del delito.

ANEXO D

INDICIO DE CALIDAD DE LA TESIS DOCTORAL

(ARTÍCULO CIENTÍFICO)



Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders

Daniel Salafranca Barreda¹ · Enzo Yaksic²

Accepted: 10 November 2022

© The Author(s), under exclusive licence to Society for Police and Criminal Psychology 2022

Abstract

Spatial analysis has long been a valuable tool within the criminal investigation process. The aim of the present research is to analyze three dispersion distribution strategies and to build a geographic profile model on the base of set theory that can determine a reference area where the search for the anchor point of a serial homicide offender (SHO) can begin. In the present study, models of circular profiles with variable distance and ellipticals generated for 84 SHOs were tested. In general, the present study found that the elliptical model performed better than the circular models, most likely due to the larger area of the ellipses. When considering police utility purposes, circular models may perform more efficiently. The implications and directions for future research are discussed.

Keywords Set theory · Venn diagrams · Dispersion · Variable distance · Predictive accuracy

Introduction

The primary goal of any investigation into the activities of a serial homicide offender (SHO) is to apprehend the individual before additional lives are lost. Law enforcement organizations (LEOs) often prefer to make such an arrest at the offender's residence to avoid the chance of a potentially lethal public encounter (Yaksic 2019). To aid in the pursuit of serial criminals, geographic profilers have access to a variety of strategies to estimate where a SHO resides. As detailed by Levine (2000), these processes distinguish probability distance distribution and spatial distribution strategies that estimate the anchor point (or domicile) of the criminal by calculating a central point from the locations of crime incidents. These include the center of the circle, the geometric mean, the median, the harmonic mean, the centroid, and the minimum distance. The classification made by the spatial distribution strategy at one point does not fit

the results obtained with other geometries.¹ For this reason, the present study uses a geographical profile that relies on a dispersion distribution strategy (Salafranca 2021), defined as the geometric characteristics of the distribution of a crime to make a prediction of a certain area.

These techniques have proven highly effective as first-approximation tools when performing geographic profiling, since they are partly based on characteristics of the principle of least effort (Leitner et al. 2007; Levine 2005; Paulsen 2006; Snook et al. 2004, 2005), but they have the disadvantage that they are susceptible to the influence of outliers that distort their effectiveness. Combining central tendency (a measure which provides an idea of the “middle” or center of distribution) and spatial dispersion has been found to be an adequate profiling technique (Kent and Leitner 2007; Levine 2006; Paulsen 2006; Snook et al. 2002). The primary question the present study seeks to answer is whether or not it is necessary to use complex techniques (i.e., probability distance distribution) or if equally accurate results can be obtained with simpler techniques as this question has yet to be properly addressed in the literature.

The purpose of the present research is to extend the line of research presented by Kent and Leitner (2007) and Rossmo (2000) and analyze three dispersion distribution strategies

✉ Daniel Salafranca Barreda
d.salafranca@crimina.es

Enzo Yaksic
yaksic.e@alumni.neu.edu

¹ Crímina Center, University Miguel Hernández, Hélike Building, University Avenue s/n, 03201 Elche, Spain

² Atypical Homicide Research Group, Boston, MA, USA

¹ Such as Newton-Swoope, Venn diagram, ellipse standard deviation, arithmetic centroid prioritization, minimum bounding rectangle, and the great circle method.

in an effort to build a geographic profile model on the base of set theory that can determine a reference area where the search for the anchor point of a SHO can begin. These three models use an algorithm that starts from the crime scene and obtains a map of circles or ellipses where the target resides in the area with the most overlap. The present research is important and justified because it offers LEOs the use of a geographic profiling strategy on which to base a search area for a SHO's anchor point that is easier to implement and more cost-effective than other models. The use of probability distance strategies and the interpretation of the results requires a fairly extensive knowledge of both the technique and the software, and acquiring these necessary skills has a significant cost (e.g., time and financial). This disadvantage provides a basis for the present research's discussion of simple versus complex methods (Bennell et al. 2007).

Set Theory

The present study intends to use set theory to allow for LEOs to locate an initial search area more easily for the SHO's home. Set theory (Rossmo 2000) refers to an area of study focused on sets (or grouping of elements) where both the attributes they possess and the relationships that can be established between them are analyzed. Since serial crimes are related, areas of overlap between two or more circles are more likely to include the offender's address. Set theory is beneficial over other models in that the theory provides a useful first approach to determining the SHO's residence from crime locations (Rossmo 2000) given that environmental criminology establishes a framework within which centrogamy and other geographic principles are valid methods. The graphic models (especially the Venn models)² associated with set theory (Cantor 1915) can explain the relationships between distances between crimes. One of the most useful properties of Venn diagrams is their ability to visualize binary relationships between sets. Using simple terminology, a set can mean a group of elements or data, which are not only agglomerated, but maintain a certain relationship between them. Each element that is part of the set, apart from being defined individually, is characterized by being a part of the set. Although the elements of the set may be differentiable from each other, they maintain some property that unites them (Silva Silva 2009). In a Venn diagram, the intersection of two sets is represented by the region that is determined by the interior of the closed curves that shape the sets. The basic relation in set theory is that of membership or non-membership which are assigned values 1 and 0, respectively,

where the higher the value, the more an item belongs to the set under examination (Zimmermann 2001). Set theory urges the user to consider that one of the overlapping areas of the circles is more likely to contain the offender's anchor point (Rossmo 2000).

The goal of the present study is to analyze three models of geographic profiles, related to circles and ellipses with variable distance on the basis of set theory, in order to define the most acceptable model in a sample of 84 SHOs. The methodology of the panel of the National Institute of Justice's (NIJ) experts (Rich and Shively 2005) was applied to accomplish this. The NIJ expert panel's purpose was to develop a fair and rigorous methodology for evaluating geographic profiling software. The incorporation of the Venn diagram represents an extension of previous research in which Kent and Leitner (2007) reviewed geographic profiling models using basic geographic rules of central tendency and spatial diffusion.

Theoretical Basis and Current Progress in Geographic Profiling Studies

There are many geographic profiling studies in the literature that focus on probability-based approaches and spatial distribution strategies. These articles offer geographic profilers a range of strategies for predicting where a serial offender is residing. These strategies are described succinctly by Levine (2000), who make the broad distinction between spatial distribution strategies and probability distance strategies. Spatial distribution strategies include a number of different procedures, all of which predict the home location of a serial offender by calculating a central point from a distribution of crime site locations. Some common spatial distribution strategies include the center of the circle, centroid, median, geometric mean, harmonic mean, and center of minimum distance. Probability distance strategies begin with the assumption that an offender's crime site locations define their activity space, and that this area contains the offender's residence (Canter et al. 2000; Rossmo 2000). The prediction of an offender's residence within this space is achieved by applying, around each crime site, a mathematical function that assigns areas, or cells, of the space a small positive real number. The numbers produced by applying the function with respect to each of the crime sites are added up to produce an overall value that is then associated with each cell of the space. The result is a surface that indicates the likelihood of an offender living at a particular location, making it possible to locate the area that is most likely to contain the offender's residence.

Since the geographic profile of an offender assumes that the delinquent individual deliberately establishes their goals, there is a connection between crimes committed by a person

² John Venn (1834–1882), an English mathematician and philosopher, Cambridge professor, author of *Symbolic logic*.

and between the anchor point (home or work) and the crime scenes. A review of environmental criminology's "journey to crime" concept (defined as the displacement of the offender from their home to the scene of the crime) suggests that the vast majority of criminals commit their crimes near their home (Hodgkinson and Tilley 2007; Lundrigan et al. 2010). This strengthens crime pattern theory's hypothesis that these types of criminals prefer to commit their crimes in areas that are familiar to them or, at least, close to their daily activities (Brantingham and Brantingham 1981).

The present authors believe that the radius of action of a perpetrator can be determined by measuring the distance between their home and their farthest crime and drawing a circle around their home on a map (Lopez 2005). If the perpetrator's home location is unknown, we can determine their range of action by measuring the distance of the farthest crimes. This technique is called the circle hypothesis and is based on the premise that a criminal's range of action can be determined by taking the most distant points in the series (Canter and Larkin 1993). If the circles are not plotted around the offender's anchor point but instead around the crime scenes, a Venn diagram would show the anchor point in the area where the circles overlap (Lopez 2005, 2017). But Van Koppen et al. (2000) have engineered a different solution. In relation to the crime typology and geographic area, they calculate the distances between the anchor point and the series of crimes committed by the known perpetrator and then equate the range of action of all the perpetrators with the median of these values, generating an overlap between the circles. This overlap will occur mainly in the space within the crime scenes, which means that there is domocentricity with this technique.

Using this range of operations, the criminal's place of residence can be estimated in multiple steps. First, circles are drawn around the crime scenes with the radius of the circles determined by what is known from previous research on the mobility of offenders in a similar environment (Beijsterveldt 2006). Second, the areas in which the circles show the greatest overlap are the areas in which an offender should be sought (Van Koppen et al. 2000) per the Venn diagram method (Van Der Kemp 2014). Knowing the distance of the crime from the home, the probability that the home is within the area where the circles intersect (Rossmo 2000) can be estimated.

Model Design

Gang's Variable Distance Model

To overcome the problems posed by distances, Gang et al. (2014) establish a variable distance model. The design of the model is based on the following steps: First, an algorithm

calculates the distance from the second incident to the first incident, tracing a radius between them, which creates the first circle. Second, the process is repeated, from the third to the second and so on with all the incidents in the series. We can then obtain a map full of circles and analyze them by means of the Venn diagram where the areas that overlap correspond to the largest probability of being the goal (Gang et al. 2014). This process can be seen as a simple dichotomous function that depends only on whether or not a point lies within one of the circles. The results are shown in Fig. 1 following this algorithm, where the red zone is the most likely.

Newton's Circle Model

The next analyzed variable distance model is the geographic profiling analysis technique based on Newton's circles (1988), which is a practical method to measure these characteristics. It is interesting to note the differences observed between Newton's technique and other methodologies based on circles, due to its reduction as a function of the applied spatial extension and the number of incidents. In the Newton method, there are three different peculiarities (Kent and Leitner 2007; Newton 1988): first, the planned address will be closer to the true address; second, the search area will narrow with the addition of each additional crime series; and lastly, the real address will be located in the area of the maximum overlap of the circles (i.e., the profile accuracy). In this last phase, a modification has been made in relation to Newton's original algorithm. The results are shown in Fig. 2 following this algorithm, where the red zone is the most likely. Some studies suggest that criminals prefer a specific travel direction when traveling from their home to the crime scene (Godwin 2001). If this is truly the case, then we can greatly narrow the search area as an alternative to the circle.

Standard Deviation Ellipse Model

The third model proposed is the standard deviation ellipse, which can better explain the inherent impedance factors that we can find in the landscape which highlights irregularities. Similar to the circle, the ellipse is able to identify the center of a distribution, and its spatial extensions (i.e., scatter). But different from the circle, an ellipse measures the shape and the orientation distribution by summarizing the maximum and minimum variance along the x - and y -axes. By using the ellipse to perform the analysis, we are measuring not only the center of the distribution but also the distribution and the shape of the orientation and the minimum and maximum variance in the x - and y -axes (Ebdon 1988). The results are shown in Fig. 3 following this algorithm, where the red zone is the most likely.




Fig. 1 Model Gang. Geographical profiling of The Yorkshire Ripper. Prepared by the author

Methods

Data

Because there is no one definition of serial murder due to decades of disagreement among experts (Adjorlolo and Chan 2014; DeLisi and Scherer 2006; Yaksic 2015, 2018; Yaksic et al. 2021), the present research utilized a specific set of components from popular definitions. To be included in the present analysis, a SHO must have committed four or more homicides, in separate events, with a “cooling off” period in the intervals between murders that could last for hours, days, months, or years. Events must have occurred

over a period greater than 14 days to abide by the parameters set forth in Schlesinger et al. (2017) and Yaksic (2019) where it was determined that serial murderers who kill their victims within an interval of 1–14 days could be considered spree killers. The physical address of the SHO’s domicile (anchor point) and the locations of their crimes must have been verifiable.

The inclusion criteria were based on access to multiple sources of verifiable data which allowed the authors to perform cross-checks and establish factual validity. Data from the Consolidated Serial Homicide Offender Database (CSHOD) was used in this study. The CSHOD is a product of merged records from independently built databases




Fig. 2 Model Newton. Geographical profiling of The Yorkshire Ripper. Prepared by the author

maintained and contributed by scholars who are members of the Atypical Homicide Research Group (AHRG) (Aamodt et al. 2022). The CSHOD is a filterable database designed to allow users to curate the data to fit their given inclusion and exclusion criteria and allows users to select the serial murder definition that best suits their research study. While the AHRG does not endorse one particular serial murder definition over another, the CSHOD was designed to be as comprehensive as possible. The CSHOD is comprised of records obtained through (1) scholarly journal articles, (2) court and prison records, (3) textbooks, (4) news articles, (5) contributions from law enforcement, (6) Freedom of Information Act requests, (7) Internet searches, (8) personal files, (9) social media, and (10) true crime books. A database

coordinator is responsible for overseeing the process of verifying information. The validity of the data is maintained by consistent cross-checks of old and new information against daily Internet searches for the terms “serial killer,” “serial homicide,” and “serial murder.” Any new additions to the database are scrutinized by at least two coders and measured against at least two independent sources. Data are only input into the database after approval by the coordinator.

While the CSHOD contains data on all subsets of serial murderers who victimize acquaintances, family members, intimate partners, and strangers in various settings (e.g., college campuses, medical or nursing facilities, private residences) and scenarios (e.g., arguments, domestic violence, robberies, sexual encounters), serial




Fig. 3 Model ellipse SD1. Geographical profiling of The Yorkshire Ripper. Prepared by the author

murderers must be responsible for at least two homicides, committed in separate events, to be included in the CSHOD. Additionally, homicide events must occur across at least two locations, either in a rapid, spree-like sequence, or a longer time span of days, weeks, months, or years. A variety of motives identified from the offender's personal statements and/or media reports include (1) anger (e.g., anti-government beliefs, domestic disputes, racial hatred, revenge), (2) convenience (e.g., eliminate witnesses, undesired relatives), (3) criminal negligence (e.g., over-prescription of drugs, reckless indifference), (4) enjoyment (e.g., control, pleasure, power, thrill), (5) financial (e.g., access to spousal resources, burglary, professional contract, robbery), (6) attention (e.g., fame, celebrity), (7) avoid arrest (e.g., escape apprehension), (8) torture (e.g., inflicting pain and suffering), (9) mental illness (e.g., paranoia, schizophrenia), (10) random

attacks, (11) sexual assaults, (12) multiple motives, or (13) unknown. Users of the CSHOD may sort by and remove any of the subcategories within the 13 overarching motive categories that do not fit their study aims. Data from the CSHOD have been used in recent studies that reviewed serial homicide time intervals (Yaksic et al. 2021), spree killing (Yaksic 2019), geographical profiling (Salafranca 2021), careers (Campedelli and Yaksic 2022), and teams (Yaksic et al. 2021).

Serial murderers who killed two victims were excluded from the present analysis given the controversy surrounding the inclusion of these offenders as they are thought to be different from traditional serial murderers across a variety of key characteristics (Yaksic 2018). Serial murderers who killed three victims were excluded to allow for a greater number of locations that could be mapped. This study focused on serial murderers who killed four or more people so that additional data points

could be considered for analysis. To avoid such confusion, the present analysis included “true” serial murderers or those who conformed most closely to the literature base. Victims could have shared any type of relationship with the offender, including acquaintance, family, or stranger. Guided by logic presented in previous literature on serial murder (Hickey 2015), the analysis was limited to serial homicide series that concluded after 1929 given concerns with the veracity of data before that time, issues that arose due to substandard record keeping, a lack of definitional consensus, and varied classification schemes for serial murders. The following exclusions were made: 1259 two-victim serial murderers, 866 three-victim serial murderers, and 1797 whose records contained missing information.

The final sample of 84 SHOs (see Appendix) was obtained after applying the exclusion criteria. The number of victims per offender ranged from 4 to 20. It can be difficult to establish true victim counts due to SHOs that complicate investigations by fabricating claims of additional victims (Edelstein 2019). Therefore, the estimates were calculated based on a cross-validation of at least two sources. Because spatial variables were not included in the CSHOD, the authors searched for information that would allow for geocoding of the places of the SHO’s crimes. For example, a search of the list of references in Kerr (2011), revealed the existence of twenty-four cases with spatial identification of the location of the crimes. The authors repeated this process of gathering information until the appropriate data was obtained for all SHOs.

For the purposes of this study, the offender model was identified as marauder and commuter. Marauders are offenders who have a fixed starting point and commit their crimes near this starting point (immediate living environment). Commuters, however, do not have a fixed starting point when committing their crimes, as they travel to a particular area and determine from there where they will commit their crime. The proposed distinction between marauders and commuters arose originally from Canter and Larkin (1993) model of the spatial behavior of criminals during the execution of serial offences. The process of classifying an offender as either a marauder or commuter is automated by calculating the relationship between the maximum distance between the crime incidents and the offender’s anchor point and the maximum distance between the two furthest crime incidents using the following equation;

$$\text{OffenderModel} = \frac{d_{cr}}{d_{cc}}$$

where d_{cr} is the distance from the farthest crime to the offender’s residence and d_{cc} is the furthest distance between criminal incidents. The offender was categorized as a marauder if the ratio was less than 1.0 or a commuter if the ratio was equal or greater than 1.0 (Kent and Leitner 2007). The average number of victims ranged from 4 to 20. Based on

observed travel behavior, 71.8% of murderers are marauders and 28.2% are travelers.

Procedure for Each Geographic Profile Strategy

The comparative evaluation of the circular profiles of Newton, Gang, and the ellipticals of Levine were carried out in three phases. First, the crime scenes and the SHO’s homes were organized according to their status as either a commuter or a marauder. Second, to achieve the analysis method, the mathematical model (Figs. 1, 2 and 3) was implemented using the Scripting language in Python for a QGIS environment (QGIS Geographic Information System 2020). The circle hypothesis was run from the second series, creating a map displaying an area where the residence of an offender is likely to be located. This search area focuses on the geographic center (geometric mean) in the case of Newton’s model and between the distances of each series in the Gang model. As each new crime scene is incorporated into the standard procedure, the points obtained are processed again, adjusting the search area, changing position, and recalibrating the dimension of the circle.

In relation to the profile based on the standard deviation ellipse, we decided to choose Levine (2006) where there are corrections for degrees of freedom with a square root of 2, and a polygon vector layer with the standard deviation ellipse is produced. The process begins with an elliptical search area of variable size centered on the geographic center of a distribution, sequentially determined by the variance calculated on the minor and major axes. In each process that a new criminal incident is incorporated, the geographic center is recalculated, which adjust and reposition the ellipse to the profile. In the third stage of the process, the generated geometric figures are superimposed (i.e., ellipses, circles) where the area in which they converge indicates the existence of a subset that has characteristics that are common to them; in the remaining area, characteristic of each figure, the elements that belong only to this one are located. Since the crimes are related, there is a high probability that one of the overlapping areas is the anchor point (Rossmo 2000) with the highest probability being in the region where the circles intersect (Van Der Kemp 2014).

Measuring the Accuracy of Geographic Profiling Strategies

To analyze and evaluate the results, we followed the methodology of the NIJ expert panel (Rich and Shively 2005). Although the report reviewed several measures for evaluating geographic profiles, some of these measures were found to be controversial (Levine 2005; Rossmo 2005). However, there is currently no one standard for measuring performance




Fig. 4 Model ELLIPSE measuring the accuracy of geographic profiling strategies. Prepared by the author

(Rich and Shively 2004). Based on their applicability to this study, three of the performance measures listed in the NIJ report were chosen to compare the efficacy of circular and elliptical model output: profile accuracy, profile error distance, and profile search area score (Kent and Leitner 2007). Profile accuracy is a binary test of whether the actual location of the offender's residence is within the upper profile region and is reported as "yes or no." Profile error distance is a modified measure that involves taking the Euclidean distance (defined as the square root of the sum of squares of the difference of each attribute of the two elements) between the known address to the nearest axis of the final expected search area of a profile (i.e., the area of greatest overlap) where shorter distances indicate better results. The strength of this measurement goes beyond a simple dichotomous measure of the profile accuracy as it ascertains the usefulness of the profile area. In providing a measure of how far the upper profile area is from the actual location of the offender, the profile search area score is a measure which indicates how much of the required search area was predicted by the model. The score was measured as the ratio of the predicted search area (i.e., modeled output) to the required search area (i.e., theoretical search area needed to encompass the offender's residence). To calculate the required search area, the top profile output was scaled until its outer edge intersected the offender's residence. The resulting ratio provided a relative measure of search cost where higher scores values indicate more accurate profile output. Although obtaining a proportion measure relative to the search came at the detriment of being able to determine values with higher scores, the process yielded a more precise profile (Fig. 4) (Kent and Leitner 2007).

Results

Profile Accuracy

The accuracy of the profile was judged based on whether the location of the anchor point geographically coincided

with a profile's intended search area, defined as the area of maximum overlap. The cases that are within the region of maximum overlap are detailed in Table 1. The elliptical geographic profiles were accurate for 32 of 84 (38.09%) series in the case of marauding SHOs. Gang's circular model performed equally well, accurately predicting 17 of 84 (23.80%) series for marauding SHOs. The performance observed for the three models with traveling criminals has been very low 8 of 84 (9.52%). Of those predictions, only one model (5.95%) predicted the anchor point of 5 offenders in the final search area. With a 44.04% accuracy rate, the elliptical model shows a definite improvement in the technique's ability to predict an offender's anchor point.

Profile Error Distance

Table 2 provides descriptive information about the different profile models analyzed, the profile search area, and the error distance for each type of offending model (commuter-marauder). In the present research, the mean would be a questionable statistic to report in the current context, since the distributions are highly skewed. Interquartile ranges (IQR) were reported to provide an indication of data distribution around the median, which offer a vision of the data in the distribution. The means are reported for reference purposes for use in meta-analysis by other researchers.

The results of the error distance of the profile of Table 2 indicate that the behavior of the ellipse model is the most optimal, offering the shortest distances in the cases of marauder and commuter (1.65 km and 4 km, respectively).

Table 1 Profile accuracy (marauder-commuter)

Profile model N= 84	Commuter profile accuracy	Marauder profile accuracy
Gang	3 (3.57%)	17 (23.80%)
Ellipse	5 (5.95%)	32 (38.09%)
Newton	0 (0.00%)	9 (10.71%)

Table 2 Profile model summary results

Profile model	Profile search area km ² [Commuter] N:23		Profile search area km ² [Marauder] N:61		Profile error distance km [Marauder] N:61		Profile error distance km [Commuter] N:23	
	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)
Gang	0.216 (0.383) [0.008–1.32]	0.012 (0.003–0.23)	7.05 (48.72) [0–381.2]	0.244 (0.02–1.34)	13.47 (45.04) [0.77–331.7]	2.63 (0.8–4.3)	51.28 (106.9) [0.24–452.3]	9.5 (2.9–22.3)
Ellipse 1 (SD)	0.550 (0.665) [0–2.21]	0.279 (0.030–0.65)	8.16 (25.3) [0–166.6]	0.973 (0.19–3.38)	11.52 (32.02) [0.11–208.9]	1.65 (0.6–4.5)	31.42 (71.22) [0.42–273]	4 (1.8–9.8)
Newton	0.023 (0.037) [0.050–0.15]	0.006 (0.001–0.036)	0.81 (2.04) [0.2–9.76]	0.065 (0.010–0.029)	18.10 (33.21) [1–168.9]	5.09 (1.7–16)	73.38 (138) [2.3–597.3]	12.22 (5.9–50.7)

However, Gang’s circular model (with a distance score of 2.63 km for marauders was only 0.98 km shorter than that for ellipses) has behaved with a substantial difference to Newton’s circular model with a score of 5.09 km. The marauding criminals obtained shorter profile error distances in the three models analyzed.

For this evaluation technique, the Friedman test compared and classified the measured error distances for each model (Table 3).

The lowest mean range difference of 1.74 and 1.3 was assigned to the marauders and commuters, respectively, in the ellipse 1 (SD) model, indicating better performance. The error distances for this model were frequently shorter than those produced by the circular models. In contrast, Newton’s circular model ranked last in comparisons (range = 2.38 and 2.6) for marauders and commuters, indicating that this technique, on average, produced error distances that were often greater compared to the other models.

Friedman’s test for samples related to *K* indicate that there are statistically significant differences in the profile error distances between the models (chi-square = 10.87, *df* = 2, *p* < 0.004) in the case of marauders and (chi-square = 22.26,

df = 2, *p* 0.001) for commuters. Importantly, these differences are largely due to significant differences in the size of the overlapping area of the upper profiles (chi-square = 24,255, *df* = 2, *p* < 0.0001) in marauders and (chi-square = 18,348, *df* = 2, *p* 0.0001) in commuters and their subsequent impact on the profile error distance.

To improve the comparisons between measures, we have also conducted some pairwise comparisons through a non-parametric technique called the one-sided Wilcoxon signed-rank test. This test determines if an algorithm is significantly better than another by comparing their results on all the datasets at a confidence level $\alpha = 0.05$. Pairwise comparisons in Table 4 represent the number of times that a particular model produced the shortest (best), furthest (worst), or equal (tie) error distance compared to all other estimates. The ellipse model (SD1) obtained a higher performance with more estimates with equal or shorter error distances than those produced by the other techniques (in the case of the Gang 53 circular (63.09%) and in the case of Newton 63 (75%)).

In terms of the test data, however, there is no statistically significant difference in the distributions of distance errors

Table 3 Friedman test statistics

	Profile search area [Commuter] Friedman rank (A)	Profile search area [Marauder] Friedman rank (B)	Error distance [Marauder] Friedman rank (C)	Error distance [Commuter] Friedman rank (D)
Gang	1.95	1.85	1.92	2.0
Ellipse 1 (SD)	2.65	2.50	1.74	1.3
Newton	1.39	1.64	2.38	2.6

Friedman test statistics, *N* = 84, $\alpha = 0.05$, commuter *N* = 23, marauder = 61

(a) $X^2 = 18.348$, *df* = 2, *p* < 0.0001

(b) $X^2 = 24.255$, *df* = 2, *p* < 0.0001

(c) $X^2 = 10.87$, *df* = 2, *p* 0.004

(d) $X^2 = 22.26$, *df* = 2, *p* < 0.0001

Table 4 Wilcoxon signed-rank test for pairwise comparisons of modeled error distance

	Gang and ellipse	Gang and Newton	Ellipse and Newton	Sum
Combined results: <i>Z</i>	-2.252	-3.679	-4.875	
Asymp. sig (2-tailed)	0.024	0.000	0.000	
Success	31	57	63	151
Failure	52	27	21	100
Tile	1	0	0	1
Commuter results: <i>Z</i>	-2.646	-2.677	-3.528	
Asymp. sig (2-tailed)	0.008	0.007	0.000	
Success	5	18	21	44
Failure	18	5	2	25
Tile	0	0	0	0
Marauder results: <i>Z</i>	-0.920	-2.575	-3.358	
Asymp. sig (2-tailed)	0.357	0.010	0.001	
Success	26	39	42	107
Failure	34	22	19	75
Tile	1	0	0	1

between the Gang and ellipse models (SD1) when looking at the offender model (marauders) (Wilcoxon signed-ranks test, $p=0.357$, Asymp. sig (2-tailed)). Therefore, the hypothesis that the distribution of the two samples is the same in favor of the alternative hypothesis cannot be rejected.

Profile Search Area Score

Elliptical models again outperformed the circular model (see Table 3). However, it was not found that the difference between the marauding delinquent classification and the Gang and Newton circular profile was significantly different

according to the Wilcoxon signed rank test ($Z = -1.706$, $p < 0.088$) (Table 5).

Individual comparisons for each evaluation technique are provided in Tables 4 and 5. These tables detail how often a model worked compared to other techniques. The results were compared using non-parametric tests. The Friedman test was applied to the entire group and was used to determine if the modeled result was different for each measure.

The results of the Friedman test for samples related to *K* indicate that there are statistically significant differences in the profile search area score between the methods (chi-square = 18,348, $df = 2$, $p < 0.0001$) for commuter and

Table 5 Wilcoxon signed-rank test for pairwise comparisons of modeled profile probability profile search area score

	Gang and ellipse	Gang and Newton	Ellipse and Newton	Sum
Combined results: <i>Z</i>	-4.567	-2.564	-5.945	
Asymp. Sig (2-tailed)	0.000	0.010	0.000	
Success	61	33	15	109
Failure	23	51	69	143
Tile	0	0	0	0
Commuter results: <i>Z</i>	-3.346	-2.585	-4.045	
Asymp. Sig (2-tailed)	0.001	0.010	0.000	
Success	17	7	2	26
Failure	6	16	21	43
Tile	0	0	0	0
Marauder results: <i>Z</i>	-3.595	-1.706	-4.816	
Asymp. Sig (2-tailed)	0.000	0.088	0.000	83
Success	44	26	13	100
Failure	17	35	48	0
Tile	0	0	0	0

$\alpha = 0.05$

(chi-square = 24,255, $df = 2$, $p = 0.0001$) for marauder. The p -value indicates that the probability of rejecting the null hypothesis, even if it is true, is less than 0.0001. In that case, we conclude that we can safely reject the null hypothesis and that there is no difference between the profile search area scores.

Discussion

The aim of the present study is to analyze three dispersion distribution strategies to build a geographic profile model on the basis of set theory that can determine the best performance of the model and measure the theoretical and operational effectiveness in LEOs.

In practical terms, the accuracy of the profile error distance measurement has been balanced by overlapping with the size of the average upper profile area, relative to the total areas of the circular and elliptical models. Specifically, as the area of the upper profile becomes larger, the measure of the profile error distance will decrease while simultaneously becoming less useful in reducing the area of the crime domain during an investigation. Although these search areas may not be as large as those derived from the circle hypothesis (Canter and Larkin 1993), such reference areas have been reduced enough to allow LEOs to initiate a search. In this sense, the upper profile areas have been minimized by incorporating in the dispersion strategy models and the maximum overlap of the resulting geometries. The Venn diagram model has been significantly improved by minimizing the search areas associated with estimating the home of a marauding SHO. However, there are some disadvantages to the Venn diagram method, in those series where not all circles overlap (Bots 2010; Captein 2009) or in those repeated areas with maximum overlap. Following the line of work of Canter et al. (2013) in both disadvantages, the smaller area has been used to define the area of maximum overlap.

One primary finding of the present study is that the elliptical model performed better than circular models, with a 44.04% profile coincidence with the search area. The present research demonstrates that the largest area of the orientation of the elliptical models representing one standard deviation (SD) of the distance from the center of the geometric mean matches the direction and shape of the crime scene patterns more accurately. In the case of the marauders, no significant differences were found in the distances of the elliptical model and the variable distance Gang circular model. No significant differences were found in the profile search area scores in the circular models. These findings point to important differences between the delinquent models and in the choice of the profile model. While elliptical models may be

the most accurate in terms of profile error distance, it can be practically less useful than the Gang circular model since it has a much smaller average upper profile area and only a slightly less accurate profile error distance measurement. The accuracy of the method against travelers was poor. This is in line with Levine's conclusions based on his validity test for criminals who do not live in the center of their distribution (Levine 2014).

The results of the present study are in line with much of the journey to crime studies that have shown that different types of offenders differ in the distances they travel (Canter and Hammond 2006; Canter and Gregory 1994; Capone and Nichols 1976; Hammond and Youngs 2011). Because the present study employed data from a large span of time, beginning in 1929, it stands to reason that many aspects of society have evolved since then, namely transportation methods and geographic boundaries. By not using functional distances, such as those used in some cases in probability distance strategies, these changes to society have little impact on the exploration of nodes and routes in the framework of the so-called journey to crime.

We recommend that LEOs work to develop methods to determine in advance whether or not a series involves a traveler or a marauder and establish procedures to handle both types of cases. It is also possible to consider more aspects in geographic analysis than just the factor of distance and take those aspects into account in calculations. Some authors attempt to account for directional effects or assign weights to certain crime scenes even though the underlying assumptions on the basis of which they report are based on moderate evidence or are simply not explicit (Godwin 2000; Rossmo 2000).

Limitations

There are several limitations to the present study. First, the proposed methodology assumes an isotropic surface where the obstacles are uniform in all directions. As a consequence, these models do not adapt to the inherent variations exhibited by a particular transport network, such as route, direction, speed, landscape features, and urban development when executing the algorithms. Although this is consistent with current probabilistic profiling models that assume an isotropic surface where the spatial impedances are uniform in all directions, few methods include geographic actors (functional distances) in their geographic profiling analysis as a variable that influences the offender's spatial behavior. For that reason, it is necessary to determine how to calibrate the methodology for specific jurisdictions. Second, although the aim of the present study is to increase the knowledge about

the special relationships of those involved and facilitate the development of typologies of events, it was limited in that the offender's data cannot be known at the beginning of the process. Third, the corresponding average travel distance is not yet known for each crime (Bots 2010) and that several areas may arise where the same amount of overlap can be seen.

The solution to the calibration of the superimposed circles model was proposed by Van Koppen et al. (2000) and calculates all distances between the home and crime locations for each known offender, crime type, and geographic area. The median of these distances is then calculated which results in the operating range of all offenders within that geographic area. The radius is the average distance that is applied to other perpetrators of solved crimes of the same crime type in a similar environment (Beijsterveldt 2006) and, therefore, may vary depending on the crime type. As a result, a larger or smaller overlap area is obtained as the search area. The point where all the circles overlap is the point or area where the perpetrator likely resides (Van Koppen et al. 2001, 2002). This method may have been applicable to the present research as it is based on empirical data of the travel distances of offenders for various crimes and because the radius of the circles around the crime scenes can be adjusted (Van Koppen et al. 2002), but it is not yet known what the corresponding average travel distance is for each crime (Bots 2010) which is why this methodology was not utilized for the present study.

Implications and Conclusions

Although spatial issues and mobility among criminals is well established in the literature, the present study sought to deepen its understanding using a sample of SHOs. Tita and Griffiths (2005) argue that many homicides involve movement as victims and offenders interact in both time and space. This mobility is associated with event characteristics as opposed to characteristics of either the offender or victim. The empirical evidence from spatial behavior analysis highlights the importance of these situational factors in the serial offender's decision-making (Beauregard and Leclerc 2007; Deslauriers-Varin and Beauregard 2014) as they take into account the risks of approaching their victims and must consider, among other factors, the current place and the present moment (Hewitt and Beauregard 2014). Another approach to the analysis of the mobility of offenders that aims to better understand the convergence of offenders and victims in the same space-time coordinates consists of the so-called "mobility triangles" (Groff and McEwen 2007). This is a strategy that allows for the examination of the offender's mobility in

terms of the relative position of their residence, the victim, and the crime scene which creates a triangle.

To the extent that we are able to establish a relationship between crime patterns and geometry, the presence of certain key characteristics, as well as the distance between the series, may become indicators of interest and raise hypotheses. The proposed methodology could be applied by LEOs that do not have the commercial tools necessary to generate probability distance strategies. From the point of view of academic research, the present study provides a vision and a work methodology to deepen the understanding of the mobility patterns of SHOs and can also be extrapolated to other criminal typologies.

In summary, the principles of distance decay, crime-free zones, and direction of travel do not appear to add value to the results of geographic offender profiling. In essence, the simplest technique for determining a SHO's geographic profile (i.e., the circle technique) is as effective as the more complicated techniques (Lopez 2017). The use of simpler strategies is consistent with several studies, such as that of Snook (2000), in which students with no prior knowledge of geographic profiling of offenders were able to make judgments based on two decision rules as accurate as the results using probability distribution strategies. This does not mean that approaches using more complicated techniques should now be discarded a priori. The effectiveness of geographic profiling of SHOs is not determined solely by the technique chosen, but primarily by the way in which the technique is applied by geographic profilers and within LEOs. In this sense, the better the coordination of geographic profiling of SHOs with other forms of information and/or methods of offender detection, the greater its practical utility.

Due to its complex nature, attempting to connect multiple locations with SHOs using geographical analysis is often challenging. Future studies should consider these challenges, such as how the SHO's cooling-off period and its relationship with distance complicates the process and takes those issues into account in calculations. Future research should interrogate Kim, Chun, and Gould (2013) framework for understanding homicide from a sociogeographic perspective using a Geographic Information System as it is not currently known to what extent these techniques behave in the dispersion distribution models. In the end, the present research introduces a set of ideas that researchers, geographic profilers, and LEOs can review when searching for a simpler and cost-effective alternative to current practices. We support further research in this area and offer the present study to inspire others to carry forward such work. The present study advocates for the use of the simplest technique for determining a SHO's geographic profile in the hopes of lessening the impact that SHOs have on society.

Appendix

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
1	Kenneth	Bianchi	USA	8	10/1977–1/1979	General public, female
2	Donato	Bilancia	Italy	5	10/1997–4/1998	General public, male/female
3	David	Birnie	Australia	4	10/1986–11/1986	General public, female
4	Robert	Black	Northern Ireland, England, Scotland	4	8/1978–3/1986	General public, female children
5	Ian	Brady	England	5	7/12/1963–10/6/1965	General public, male/female
6	Dean	Carter	USA	4	1984–1984	Home invasion, female
7	Jeffrey	Dahmer	USA	5	6/18/1978–7/19/1991	Sex workers, male
8	Albert	Desalvo	USA	13	6/14/1962–1/4/1964	General public, female
9	Sipho	Dube	South Africa	6	2001–11/8/2003	General public, children
10	Marc	Dutroux	Belgium	4	8/22/1995–1996	General public, female
11	Cristopher	Dwayne	USA	7	10/30/1990–12/8/1990	General public
12	Kenneth	Erskine	England	6	4/9/1986–7/23/1986	Home invasion, elderly females
13	Cordell	Farrington	Bahamas	4	5/16/2003–9/28/2003	General public, male children
14	Lorenzo	Fayne	USA	6	7/14/1989–7/24/1993	General public, female children
15	Joaquin	Ferrandiz	Spain	5	7/2/1995–9/14/1996	Female
16	Danny	Figueroa	USA	4	5/13/1986–6/17/1986	General public
17	Roy	Fontain	England	5	9/01/1977–1/16/1978	General public
18	Michel	Fourniret	France	8	12/11/1987–5/5/2001	General public, female
19	Ferdinand	Gamper	Italy	4	2/8/1996–3/1/1996	General public
20	John	Glover	Australia	6	3/1/1989–11/24/1989	General public, female
21	Steven	Grieverson	England	4	5/26/1990–4/25/1994	General public, male children
22	John	Haigh	England	4	9/6/1944–2/18/1949	Acquaintances
23	Leslie	Irvin	USA	4	12/2/1954–3/28/1955	Employees
24	Shantaram	Jagtap	India	5	1/16/1976–3/23/1977	Home invasion, males and females
25	Vincent	Johnson	USA	6	8/26/1999–6/7/2000	Sex workers, female
26	Anthony	Kirkland	USA	4	5/20/1987–3/7/2009	General public, female
27	Joachim	Kroll	Germany	9	2/8/1955–7/3/1976	General public, male/female
28	Peter	Kurten	Germany	5	2/8/1929–11/7/1929	General public, male children

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
29	Cesar	Legorreta	Mexico	7	7/14/2011–1/18/2012	General public, female
30	Bobby	Long	USA	9	3/27/1984–11/11/1984	Sex workers, female
31	John	Lovgren	Sweden	4	6/27/1957–9/2/1963	Home invasion, female
32	Michael	Lupo	England	4	3/15/1986–4/24/1986	Sex workers
33	Matthew	Macon	USA	6	12/20/2004–8/29/2007	Home invasion, females
34	Peter	Manuel	Scotland	5	1/2/1956–1/1/1958	Home invasion, males and females
35	Raymond	Morris	England	4	9/8/1965–8/19/1967	General public, female children
36	Tsutomu	Miyazaki	Japan	4	8/22/1988–6/6/1989	General public, female children
37	Pedro	Nakada	Peru	13	1/1/2005–12/27/2006	Homeless
38	Donald	Neilson	England	4	2/15/1974–1/14/1975	General public
39	Itzcoatl	Ocampo	USA	4	10/25/2011–1/13/2012	Homeless
40	Clifford	Olson	Canada	11	11/17/1980–7/30/1981	General public, children
41	Antonio	Ortiz	USA	4	5/24/1997–7/26/2000	General public, female children
42	Pietro	Pacciani	Italy	5	8/21/1968–9/8/1985	General public
43	Somkhid	Phumphuang	Thailand	5	1/30/2005–6/21/2005	Sex workers, female
44	Larme	Price	USA	4	2/8/2003–3/20/2003	Employees
45	George	Putt	USA	4	8/14/1969–9/11/1969	Home invasion, males and females
46	Charles	Quansah	Ghana	20	1993–2000	General public, female
47	Larry	Ralston	USA	5	9/3/1975–10/22/1977	General public, female
48	Richard	Ramirez	USA	15	6/28/1984–8/8/1985	Home invasion
49	Andre	Rand	USA	4	7/7/1972–7/9/1987	General public, female children
50	Robert	Reldan	USA	5	8/10/1974–10/24/1975	General public, female children
51	Angel	Resendiz	USA	6	1986–6/15/1999	Home invasion, females
52	Joel	Rifkin	USA	13	1989–6/24/1993	Sex workers, females
53	Michael	Ross	USA	7	5/12/1981–6/13/1984	General public, females
54	Alexander	Rubel	Estonia	7	9/19/1997–6/4/1998	General public
55	Remedios	Sanchez	Spain	8	6/10/2006–7/3/2006	Female
56	Viktor	Sayenko	Ukraine	7	6/25/2007–7/16/2007	General public
57	Manfred	Seel	Germany	5	2/6/1971–4/1/2004	Female
58	Munawar	Shah	India	5	1/16/1976–3/23/1977	Home invasion, male and female
59	Robert	Shulman	USA	5	8/1/1991–12/8/1995	Sex workers, female

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
60	Darbara	Singh	India	11	8/15/2004–10/25/2004	General public, female children
61	Mark	Smith	South Korea/ Germany/USA	4	3/12/1969–5/27/1970	General public, female
62	Peter	Sutcliffe	England	20	10/30/1975–11/17/1980	General public, female
63	Joseph	Taborsky	USA	7	3/23/1950–1/26/1957	Employees/ customers
64	Kevin	Taylor	USA	4	6/25/2001–8/18/2001	Sex workers, female
65	Richard	Trenton	USA	4	12/29/1977–1/27/1978	General public
66	Helmut	Weidenbroeker	Germany	5	4/05/1982–6/03/1986	Female
67	Rosemary	West	England	8	6/18/1971–6/19/1987	Multiple types
68	John	Williams	USA	6	1/7/1996–12/24/1996	Sex workers, female
69	Carl	Williams	Australia	5	6/15/2000–3/21/2004	Criminals
70	Michael	Wolter	Germany	8	5/7/1980–11/26/1982	General public
71	Steven	Wright	England	5	10/30/2006–12/11/2006	Sex workers, female
72	Robert	Yates	USA	11	7/13/1975–10/13/1998	Sex workers, female
73	Alfredo	Galan	Spain	5	1/4/2003–3/18/2003	General public
74	Francisco	Escalero	Spain	11	8/1/1987–4/1/1994	Homeless
75	Waldo	Grant	USA	4	9/14/1973–12/29/1976	Homosexual males
76	Colin	Ireland	England	5	3/8/1993–6/15/1993	Sex workers
77	Edmund	Kemper	USA	6	8/27/1964–4/21/1973	Hitchhikers
78	Joachim	Knychal	Poland	5	03/11/1974–5/8/1982	Female
79	William	Macdonald	Australia	5	1/6/1961–11/4/1962	Homeless
80	Lazarus	Mazingane	South Africa	16	4/13/1993–4/23/1998	General public, female
81	Vinko	Pintaric	Croatia	5	4/26/1973–8/2/1990	General public, male/female
82	Reinaldo	Rivera	USA	4	7/17/1999–9/29/2000	General public, female
83	Wolfgang	Schmidt	Germany	5	10/24/1989–4/5/1991	General public, female
84	Roberto	Arguelles	USA	4	2/21/1992–3/30/1992	General public, female

Data Availability The datasets generated during and/or analysed during the current study are available in the Harvard Dataverse repository, https://dataverse.harvard.edu/dataverse/serial_homicide.

References

- Aamodt M, Fox JA, Hickey E, Hinch R, Labuschagne G, Levin J, McClellan J, Nelson B, Newton M, Quinet K, Steiger C, White J, Yaksic E (2022) Consolidated Serial Homicide Offender Database. https://dataverse.harvard.edu/dataverse/serial_homicide
- Adjorlolo S, Chan HC (2014) The controversy of defining serial murder: revisited. *Aggress Violent Beh* 19(5):486–491. <https://doi.org/10.1016/j.avb.2014.07.003>
- Beauregard E, Leclerc B (2007) An application of the rational choice approach to the offending process of sex offenders: a closer look at the decision-making. *Sex Abuse-J Res Tr* 19(2):115–133. <https://doi.org/10.1177/107906320701900204>
- Bots K (2010) The performance of the circular method of Van Koppen, De Poot and Van Koppen. Comparison with two techniques of geographic offender profiling. Amsterdam Vrije Universiteit
- Brantingham PJ, Brantingham PL (1981) *Environmental criminology*. Sage Publications, Beverly Hills, CA

- Campedelli GM, Yaksic E (2022) Survival of the recidivistic? Revealing factors associated with the criminal career length of multiple homicide offenders. *Homicide Stud* 26(3):244–268
- Canter D, Coffey T, Huntley M, Missen C (2000) Predicting serial killers' home base using a decision support system. *J Quant Criminol* 16(4):457–478
- Canter D, Gregory A (1994) Identifying the residential location of rapists. *J Forensic Sci Soc* 34(3):169–175. [https://doi.org/10.1016/S0015-7368\(94\)72910-8](https://doi.org/10.1016/S0015-7368(94)72910-8)
- Canter D, Hammond L (2006) A comparison of the efficacy of different decay functions in geographical profiling for a sample of US serial killers. *Journal of Investigative Psychology and Offender Profiling* 3(2):91–103. <https://doi.org/10.1002/jip.45>
- Canter D, Hammond L, Juszcak P (2013) The Efficacy of Ideographic Models for Geographical Offender Profiling 29(3):423–446. <https://doi.org/10.1007/s10940-012-9186-6>
- Canter D, Larkin P (1993) The environmental range of serial rapists. *J Environ Psychol* 13(1):63–69. [https://doi.org/10.1016/S0272-4944\(05\)80215-4](https://doi.org/10.1016/S0272-4944(05)80215-4)
- Cantor G (1915) Contributions to the founding of the theory of transfinite numbers, vol 45. Dover Publications
- Capone DL, Nichols WW (1976) Urban structure and criminal mobility. *Am Behav Sci* 20(2):199–213. <https://doi.org/10.1177/000276427602000203>
- Capein M (2009) Geografische daderprofilering binnen de RPAA. Amsterdam: Politie Amsterdam-Amstelland (Geographical offender profiling within the Regional Police of Amsterdam-Amstelland (RPAA))
- DeLisi M, Scherer AM (2006) Multiple homicide offenders: offense characteristics, social correlates, and criminal careers. *Crim Justice Behav* 33(3):367–391. <https://doi.org/10.1177/0093854806286193>
- Deslauriers-Varin N, Beauregard E (2014) Consistency in crime site selection: an investigation of crime sites used by serial sex offenders across crime series. *J Crim Just* 42(2):123–133. <https://doi.org/10.1016/j.jcrimjus.2013.09.005>
- Ebdon D (1988) *Statistics in Geography*. Blackwell, Oxford
- Edelstein A (2019) Cooling-off periods among serial killers. *Journal of Psychology & Behavior Research*. 2(1):1–15. <https://doi.org/10.22158/jpbr.v2n1p1>
- Gang J, Dai Q, Li S (2014) Prediction model for law enforcement agencies on the serial criminals. *Journal of Applied Science and Engineering Innovation* 1(5):316–323
- Godwin GM (2000) *Criminal psychology and forensic technology: A collaborative approach to effective profiling*. CRC Press, Boca Raton, FL
- Godwin GM (2001) *Criminal psychology and forensic technology*. (G. M. Godwin (ed.); CRC Press). <http://www.investigativepsych.com>. Accessed 24 Jan 2022
- Groff ER, McEwen T (2014) Integrating distance into mobility triangle typologies. *Soc Sci Comput Rev* 25(2):210–238. <https://doi.org/10.1177/0894439307298924>
- Hammond L, Youngs D (2011) Decay functions and criminal spatial processes: geographical offender profiling of volume crime. *Journal of Investigative Psychology and Offender Profiling* 8(1):90–102. <https://doi.org/10.1002/jip.132>
- Hewitt A, Beauregard E (2014) Sexual crime and place: the impact of the environmental context on sexual assault outcomes. *J Crim Just* 42(5):375–383. <https://doi.org/10.1016/j.jcrimjus.2014.05.003>
- Hickey EW (2015) *Serial murderers and their victims*. Cengage Learning
- Hodgkinson S, Tilley N (2007) Policing anti-social behaviour: constraints, dilemmas and opportunities. *The Howard Journal of Criminal Justice* 46(4):385–400. <https://doi.org/10.1111/j.1468-2311.2007.00484.x>
- Kent J, Leitner M (2007) Efficacy of standard deviational ellipses in the application of criminal geographic profiling. *Journal of Investigative Psychology and Offender Profiling* 165:147–165. <https://doi.org/10.1002/jip.72>
- Kerr G (2011) Mapping the Trail of a crime: how experts use geographic profiling to solve the world's most notorious cases (Readers Digest (Ed.))
- Kim H, Chun Y, Gould CA (2013) Crime scene locations in criminal homicides: a spatial crime analysis in a GIS environment. In *Crime Modeling and Mapping Using Geospatial Technologies*. Springer, Dordrecht
- Leitner M, Kent J, Oldfield I, Swoope E (2007) Geoforensic analysis revisited—the application of Newton's geographic profiling method to serial burglaries in London. *UK Police Practice and Research* 8(4):359–370. <https://doi.org/10.1080/15614260701615060>
- Levine N (2000) CrimeStat: A spatial statistics program for the analysis of crime incident locations, vol 1.1. Ned Levine and Associates/National Institute of Justice, Annandale, VA/Washington, DC
- Levine N (2005) Response to Kim Rossmo Critique of the GP Evaluation Methodology. <http://www.nedlevine.com/Response%20to%20Kim%20Rossmo%20Critique%20of%20the%20GP%20Evaluation%20Methodology.May%208%202005.doc>
- Levine N (2006) Crime mapping and the CrimeStat program. *Geogr Anal* 38(1):41–56. <https://doi.org/10.1111/j.0016-7363.2005.00673.x>
- Levine N (2014) Journey-to-Crime Estimation. <https://www.semanticscholar.org/paper/Chapter-13-%3A-Journey-to-Crime-Estimation-Levine/5e95cde24d172530ebc965c8412e84ef02aa193a>. Accessed 24 Jan 2022
- Lopez MJJ (2005) The spatial behavior of residential burglars. Proceedings of the 5th International Space Syntax Symposium. TU Delft, Techne Press, Delft
- Lopez M (2017) Geographic offender profiling. *Result Crime Management*. <https://doi.org/10.13140/RG.2.2.28187.26408>
- Lundrigan S, Czarnomski S, Wilson M (2010) Spatial and environmental consistency in serial sexual assault. *Journal of Investigative Psychology and Offender Profiling* 7(1):15–30. <https://doi.org/10.1002/jip.100>
- Newton MB (1988) Geographical discovery of the residence of an unknown dispersing localized serial murder. Unpublished manuscript, Louisiana State University, Baton Rouge, LA
- Paulsen D (2006) Human versus machine: a comparison of the accuracy of geographic profiling methods. *Journal of Investigative Psychology and Offender Profiling* 3(2):77–89. <https://doi.org/10.1002/jip.46>
- QGIS Geographic Information System (2020) Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>. Accessed 24 Jan 2022
- Rich T, Shively M (2004) A methodology for evaluating geographic profiling software: final report. Abt Associates Inc., Cambridge
- Rich T, Shively M (2005) A methodology for evaluating geographic profiling software. 1–259. <https://www.ncjrs.gov/pdffiles1/nij/grants/208993.pdf>. Accessed 24 Jan 2022
- Rossmo DK (2000) *Geographic profiling*. CRC Press, Boca Raton, FL
- Salafranca D (2021) The application of Newton and Swoope's geographical profile to serial killers. *Journal of Investigative Psychology and Offender Profiling* 18(1):68–78. <https://doi.org/10.1002/jip.1566>
- Schlesinger LB, Ramirez S, Tusa B, Jarvis JP, Erdberg P (2017) Rapid-Sequence Serial Sexual Homicides. *J Am Acad Psychiatry Law* 45(1):72–80
- Silva Silva JA (2009) Set theory and private international law. *Mexican Comparative Law Bulletin* 126:1463–1497
- Snook B (2000, December) Utility or futility? A provisional examination of the utility of a geographical decision support system. Paper

- presented at the meeting of the Crime Mapping Research Center, San Diego, CA
- Snook B, Canter D, Bennell C (2002) Predicting the home location of serial offenders: a preliminary comparison of the accuracy of human judges with a geographic profiling system. *Behav Sci Law* 20(1–2):109–118. <https://doi.org/10.1002/bsl.474>
- Snook B, Taylor PJ, Bennell C (2004) Geographic profiling: the fast, frugal, and accurate way. *Appl Cogn Psychol* 18(1):105–121. <https://doi.org/10.1002/acp.956>
- Snook B, Zito M, Bennell C, Taylor PJ (2005) On the complexity and accuracy of geographic profiling strategies. *J Quant Criminol* 21(1):1–25. <https://doi.org/10.1007/s10940-004-1785-4>
- Tita G, Griffiths E (2005) Traveling to violence: the case for a mobility-based spatial typology of homicide. *J Res Crime Delinq* 42(3):275–308. <https://doi.org/10.1177/0022427804270051>
- Van Beijsterveldt K (2006) Traveler or poacher?: geographic offender profiling and travel patterns of property crime offenders. Rotterdam: Erasmus Universiteit (Master Thesis)
- Van der Kemp JJ (2014) Mode via: refinement of geographic offender profiling. <https://research.vu.nl/en/publications/modus-via-verfijning-van-geografische-daderprofilering>
- Van Koppen PJ, de Poot CJ, van Koppen M (2000) Circles of crimes. About the places where crimes were committed and the place of residence of the perpetrators. *The Psychologist* 35(10):435–442
- Van Koppen PJ, De Poot CJ, Van Koppen MV (2001) Identifying the domiciles of the offender: geographic offender profiling in practice. *Balaclava, Police Hat, and Gown: Interplay between Crime and Law Enforcement*. 79–98
- Van Koppen PJ, Van der Kemp JJ, De Poot CJ (2002) Geographic offender profiling. *The right inside: psychology of law*. Kluwer
- Yaksic E (2015) Addressing the challenges and limitations of utilizing data to study serial homicide. *Crime Psychology Review* 1(1):108–134. <https://doi.org/10.1080/23744006.2016.1168597>
- Yaksic E (2018) The folly of counting bodies: using regression to transgress the state of serial murder classification systems. *Aggress Violent Beh* 43:26–32. <https://doi.org/10.1016/j.avb.2018.08.007>
- Yaksic E (2019) Moving past sporadic eruptions, discursive killing, and running amok: recognizing the convergence of the serial and spree killer: recognizing the convergence of the serial and spree killer. *J Crim Psychol* 9(3):138–146. <https://doi.org/10.1108/JCP-03-2019-0009>
- Yaksic E, Simkin M, Roychowdhury V (2021) A statistical study of the time intervals between serial homicides. *J Crim Just* 73:1–10. <https://doi.org/10.1016/j.jcrimjus.2020.101751>
- Zimmermann HJ (2001) Fuzzy set theory and its applications - Fourth Edition. In Kluwer, Boston, 2nd ed., 1993. <https://doi.org/10.1007/978-94-010-0646-0>

Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Springer Nature or its licensor (e.g. a society or other partner) holds exclusive rights to this article under a publishing agreement with the author(s) or other rightsholder(s); author self-archiving of the accepted manuscript version of this article is solely governed by the terms of such publishing agreement and applicable law.

ANEXO D.1

INDICIO DE CALIDAD DE LA TESIS DOCTORAL (TRANSCRIPCIÓN ARTÍCULO CIENTÍFICO)

Salafranca Barreda, D., Yaksic, E. Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders. *Journal Police Criminal Psychology* (2022).
<https://doi.org/10.1007/s11896-022-09561-3>

Evaluating the Dispersion Strategies Used to Locate Serial Homicide Offenders

Abstract

Spatial analysis has long been a valuable tool within the criminal investigation process. The aim of the present research is to analyze three dispersion distribution strategies and to build a geographic profile model on the base of set theory that can determine a reference area where the search for the anchor point of a serial homicide offender (SHO) can begin. In the present study, models of circular profiles with variable distance and ellipses generated for 84 SHOs were tested. In general, the present study found that the elliptical model performed better than the circular models, most likely due to the larger area of the ellipses. When considering police utility purposes, circular models may perform more efficiently. The implications and directions for future research are discussed.

Keywords Set theory · Venn diagrams · Dispersion · Variable distance · Predictive accuracy

Introduction

The primary goal of any investigation into the activities of a serial homicide offender (SHO) is to apprehend the individual before additional lives are lost. Law enforcement organizations (LEOs) often prefer to make such an arrest at the offender's residence to avoid the chance of a potentially lethal public encounter (Yaksic 2019). To aid in the pursuit of serial criminals, geographic profilers have access to a variety of strategies to estimate where a SHO resides. As detailed by Levine (2000), these processes distinguish probability distance distribution and spatial distribution strategies that estimate the anchor point (or domicile) of the criminal by calculating a central point from the locations of crime incidents. These include the center of the circle, the geometric mean, the median, the harmonic mean, the centroid, and the minimum distance. The classification made by the spatial distribution strategy at one point does not fit the results obtained with other geometries¹. For this reason, the present study uses a geographical profile that relies on a

¹ Such as Newton-Swoope, Venn diagram, ellipse standard deviation, arithmetic centroid prioritization, minimum bounding rectangle, and the great circle method

dispersion distribution strategy (Salafranca 2021), defined as the geometric characteristics of the distribution of a crime to make a prediction of a certain area.

These techniques have proven highly effective as first-approximation tools when performing geographic profiling, since they are partly based on characteristics of the principle of least effort (Leitner et al. 2007; Levine 2005; Paulsen 2006; Snook et al. 2004, 2005), but they have the disadvantage that they are susceptible to the influence of outliers that distort their effectiveness. Combining central tendency (a measure which provides an idea of the “middle” or center of distribution) and spatial dispersion has been found to be an adequate profiling technique (Kent and Leitner 2007; Levine 2006; Paulsen 2006; Snook et al. 2002). The primary question the present study seeks to answer is whether or not it is necessary to use complex techniques (i.e., probability distance distribution) or if equally accurate results can be obtained with simpler techniques as this question has yet to be properly addressed in the literature.

The purpose of the present research is to extend the line of research presented by Kent and Leitner (2007) and Rossmo (2000) and analyze three dispersion distribution strategies in an effort to build a geographic profile model on the base of set theory that can determine a reference area where the search for the anchor point of a SHO can begin. These three models use an algorithm that starts from the crime scene and obtains a map of circles or ellipses where the target resides in the area with the most overlap. The present research is important and justified because it offers LEOs the use of a geographic profiling strategy on which to base a search area for a SHO's anchor point that is easier to implement and more cost-effective than other models. The use of probability distance strategies and the interpretation of the results requires a fairly extensive knowledge of both the technique and the software, and acquiring these necessary skills has a significant cost (e.g., time and financial). This disadvantage provides a basis for the present research's discussion of simple versus complex methods (Bennell et al. 2007).

Set Theory

The present study intends to use set theory to allow for LEOs to locate an initial search area more easily for the SHO's home. Set theory (Rossmo 2000) refers to an area of study focused on sets (or grouping of elements) where both the attributes they possess and the relationships that can be established between them are analyzed. Since serial crimes are

related, areas of overlap between two or more circles are more likely to include the offender's address. Set theory is beneficial over other models in that the theory provides a useful first approach to determining the SHO's residence from crime locations (Rossmo 2000) given that environmental criminology establishes a framework within which centrography and other geographic principles are valid methods. The graphic models (especially the Venn models)² associated with set theory (Cantor 1915) can explain the relationships between distances between crimes. One of the most useful properties of Venn diagrams is their ability to visualize binary relationships between sets. Using simple terminology, a set can mean a group of elements or data, which are not only agglomerated, but maintain a certain relationship between them. Each element that is part of the set, apart from being defined individually, is characterized by being a part of the set. Although the elements of the set may be differentiable from each other, they maintain some property that unites them (Silva Silva 2009). In a Venn diagram, the intersection of two sets is represented by the region that is determined by the interior of the closed curves that shape the sets. The basic relation in set theory is that of membership or nonmembership which are assigned values 1 and 0, respectively, where the higher the value, the more an item belongs to the set under examination (Zimmermann 2001). Set theory urges the user to consider that one of the overlapping areas of the circles is more likely to contain the offender's anchor point (Rossmo 2000).

The goal of the present study is to analyze three models of geographic profiles, related to circles and ellipses with variable distance on the basis of set theory, in order to define the most acceptable model in a sample of 84 SHOs. The methodology of the panel of the National Institute of Justice's (NIJ) experts (Rich and Shively 2005) was applied to accomplish this. The NIJ expert panel's purpose was to develop a fair and rigorous methodology for evaluating geographic profiling software. The incorporation of the Venn diagram represents an extension of previous research in which Kent and Leitner (2007) reviewed geographic profiling models using basic geographic rules of central tendency and spatial diffusion.

² John Venn (1834–1882), an English mathematician and philosopher, Cambridge professor, author of *Symbolic logic*

Theoretical Basis and Current Progress in Geographic Profiling Studies

There are many geographic profiling studies in the literature that focus on probability-based approaches and spatial distribution strategies. These articles offer geographic profilers a range of strategies for predicting where a serial offender is residing. These strategies are described succinctly by Levine (2000), who make the broad distinction between spatial distribution strategies and probability distance strategies. Spatial distribution strategies include a number of different procedures, all of which predict the home location of a serial offender by calculating a central point from a distribution of crime site locations. Some common spatial distribution strategies include the center of the circle, centroid, median, geometric mean, harmonic mean, and center of minimum distance. Probability distance strategies begin with the assumption that an offender's crime site locations define their activity space, and that this area contains the offender's residence (Canter et al. 2000; Rossmo 2000). The prediction of an offender's residence within this space is achieved by applying, around each crime site, a mathematical function that assigns areas, or cells, of the space a small positive real number. The numbers produced by applying the function with respect to each of the crime sites are added up to produce an overall value that is then associated with each cell of the space. The result is a surface that indicates the likelihood of an offender living at a particular location, making it possible to locate the area that is most likely to contain the offender's residence.

Since the geographic profile of an offender assumes that the delinquent individual deliberately establishes their goals, there is a connection between crimes committed by a person and between the anchor point (home or work) and the crime scenes. A review of environmental criminology's "journey to crime" concept (defined as the displacement of the offender from their home to the scene of the crime) suggests that the vast majority of criminals commit their crimes near their home (Hodgkinson and Tilley 2007; Lundrigan et al. 2010). This strengthens crime pattern theory's hypothesis that these types of criminals prefer to commit their crimes in areas that are familiar to them or, at least, close to their daily activities (Brantingham and Brantingham 1981).

The present authors believe that the radius of action of a perpetrator can be determined by measuring the distance between their home and their farthest crime and drawing a circle around their home on a map (Lopez 2005). If the perpetrator's home

location is unknown, we can determine their range of action by measuring the distance of the farthest crimes. This technique is called the circle hypothesis and is based on the premise that a criminal's range of action can be determined by taking the most distant points in the series (Canter and Larkin 1993). If the circles are not plotted around the offender's anchor point but instead around the crime scenes, a Venn diagram would show the anchor point in the area where the circles overlap (Lopez 2005, 2017). But Van Koppen et al. (2000) have engineered a different solution. In relation to the crime typology and geographic area, they calculate the distances between the anchor point and the series of crimes committed by the known perpetrator and then equate the range of action of all the perpetrators with the median of these values, generating an overlap between the circles. This overlap will occur mainly in the space within the crime scenes, which means that there is domocentricity with this technique.

Using this range of operations, the criminal's place of residence can be estimated in multiple steps. First, circles are drawn around the crime scenes with the radius of the circles determined by what is known from previous research on the mobility of offenders in a similar environment (Beijsterveldt 2006). Second, the areas in which the circles show the greatest overlap are the areas in which an offender should be sought (Van Koppen et al. 2000) per the Venn diagram method (Van Der Kemp 2014). Knowing the distance of the crime from the home, the probability that the home is within the area where the circles intersect (Rossmo 2000) can be estimated.

Model Design

Gang's Variable Distance Model

To overcome the problems posed by distances, Gang et al. (2014) establish a variable distance model. The design of the model is based on the following steps: First, an algorithm calculates the distance from the second incident to the first incident, tracing a radius between them, which creates the first circle. Second, the process is repeated, from the third to the second and so on with all the incidents in the series. We can then obtain a map full of circles and analyze them by means of the Venn diagram where the areas that overlap correspond to the largest probability of being the goal (Gang et al. 2014). This process can be seen as a simple dichotomous function that depends only on whether or

not a point lies within one of the circles. The results are shown in Fig. 1 following this algorithm, where the red zone is the most likely.

Newton's Circle Model

The next analyzed variable distance model is the geographic profiling analysis technique based on Newton's circles (1988), which is a practical method to measure these characteristics. It is interesting to note the differences observed between Newton's technique and other methodologies based on circles, due to its reduction as a function of the applied spatial extension and the number of incidents. In the Newton method, there are three different peculiarities (Kent and Leitner 2007; Newton 1988): first, the planned address will be closer to the true address; second, the search area will narrow with the addition of each additional crime series; and lastly, the real address will be located in the area of the maximum overlap of the circles (i.e., the profile accuracy). In this last phase, a modification has been made in relation to Newton's original algorithm. The results are shown in Fig. 2 following this algorithm, where the red zone is the most likely. Some studies suggest that criminals prefer a specific travel direction when traveling from their home to the crime scene (Godwin 2001). If this is truly the case, then we can greatly narrow the search area as an alternative to the circle

Standard Deviation Ellipse Model

The third model proposed is the standard deviation ellipse, which can better explain the inherent impedance factors that we can find in the landscape which highlights irregularities. Similar to the circle, the ellipse is able to identify the center of a distribution, and its spatial extensions (i.e., scatter). But different from the circle, an ellipse measures the shape and the orientation distribution by summarizing the maximum and minimum variance along the x- and y-axes. By using the ellipse to perform the analysis, we are measuring not only the center of the distribution but also the distribution and the shape of the orientation and the minimum and maximum variance in the x- and y-axes (Ebdon 1988). The results are shown in Fig. 3 following this algorithm, where the red zone is the most likely.




Fig. 1 Model Gang. Geographical profiling of The Yorkshire Ripper. Prepared by the author.

Methods

Data

Because there is no one definition of serial murder due to decades of disagreement among experts (Adjorlolo and Chan 2014; DeLisi and Scherer 2006; Yaksic 2015, 2018; Yaksic et al. 2021), the present research utilized a specific set of components from popular definitions. To be included in the present analysis, a SHO must have committed four or more homicides, in separate events, with a “cooling of” period in the intervals between murders that could last for hours, days, months, or years. Events must have occurred over a period greater than 14 days to abide by the parameters set forth in Schlesinger et al. (2017) and Yaksic (2019) where it was determined that serial murderers who kill their victims within an interval of 1–14 days could be considered spree killers. The physical

address of the SHO's domicile (anchor point) and the locations of their crimes must have been verifiable.

The inclusion criteria were based on access to multiple sources of verifiable data which allowed the authors to perform cross-checks and establish factual validity. Data from the Consolidated Serial Homicide Ofender Database (CSHOD) was used in this study. The CSHOD is a product of merged records from independently built databases




Fig. 2 Model Newton. Geographical profiling of The Yorkshire Ripper. Prepared by the author.

maintained and contributed by scholars who are members of the Atypical Homicide Research Group (AHRG) (Aamodt et al. 2022). The CSHOD is a filterable database designed to allow users to curate the data to fit their given inclusion and exclusion criteria and allows users to select the serial murder definition that best suits their research study. While the AHRG does not endorse one particular serial murder definition over another, the CSHOD was designed to be as comprehensive as possible. The CSHOD is comprised

of records obtained through (1) scholarly journal articles, (2) court and prison records, (3) textbooks, (4) news articles, (5) contributions from law enforcement, (6) Freedom of Information Act requests, (7) Internet searches, (8) personal files, (9) social media, and (10) true crime books. A database coordinator is responsible for overseeing the process of verifying information. The validity of the data is maintained by consistent cross-checks of old and new information against daily Internet searches for the terms “serial killer,” “serial homicide,” and “serial murder.” Any new additions to the database are scrutinized by at least two coders and measured against at least two independent sources. Data are only input into the database after approval by the coordinator.

While the CSHOD contains data on all subsets of serial murderers who victimize acquaintances, family members, intimate partners, and strangers in various settings (e.g., college campuses, medical or nursing facilities, private residences) and scenarios (e.g., arguments, domestic violence, robberies, sexual encounters),




Fig. 3 Model ellipse SD1. Geographical profiling of The Yorkshire Ripper. Prepared by the author.

serial murderers must be responsible for at least two homicides, committed in separate events, to be included in the CSHOD. Additionally, homicide events must occur across at least two locations, either in a rapid, spree-like sequence, or a longer time span of days, weeks, months, or years. A variety of motives identified from the offender's personal statements and/or media reports include (1) anger (e.g., anti-government beliefs, domestic disputes, racial hatred, revenge), (2) convenience (e.g., eliminate witnesses, undesired relatives), (3) criminal negligence (e.g., over-prescription of drugs, reckless indifference), (4) enjoyment (e.g., control, pleasure, power, thrill), (5) financial (e.g., access to spousal resources, burglary, professional contract, robbery), (6) attention (e.g., fame, celebrity), (7) avoid arrest (e.g., escape apprehension), (8) torture (e.g., inflicting pain and suffering), (9) mental illness (e.g., paranoia, schizophrenia), (10) random attacks, (11) sexual assaults, (12) multiple motives, or (13) unknown. Users of the CSHOD may sort by and remove any of the subcategories within the 13 overarching motive categories that do not fit their study aims. Data from the CSHOD have been used in recent studies that reviewed serial homicide time intervals (Yaksic et al. 2021), spree killing (Yaksic 2019), geographical profiling (Salafranca 2021), careers (Campedelli and Yaksic 2022), and teams (Yaksic et al. 2021).

Serial murderers who killed two victims were excluded from the present analysis given the controversy surrounding the inclusion of these offenders as they are thought to be different from traditional serial murderers across a variety of key characteristics (Yaksic 2018). Serial murderers who killed three victims were excluded to allow for a greater number of locations that could be mapped. This study focused on serial murderers who killed four or more people so that additional data points could be considered for analysis. To avoid such confusion, the present analysis included "true" serial murderers or those who conformed most closely to the literature base. Victims could have shared any type of relationship with the offender, including acquaintance, family, or stranger. Guided by logic presented in previous literature on serial murder (Hickey 2015), the analysis was limited to serial homicide series that concluded after 1929 given concerns with the veracity of data before that time, issues that arose due to substandard record keeping, a lack of definitional consensus, and varied classification schemes for serial murders. The following exclusions were made: 1259 two-victim serial murderers, 866 three-victim serial murderers, and 1797 whose records contained missing information.

The final sample of 84 SHOs (see Appendix) was obtained after applying the exclusion criteria. The number of victims per offender ranged from 4 to 20. It can be difficult to establish true victim counts due to SHOs that complicate investigations by fabricating claims of additional victims (Edelstein 2019). Therefore, the estimates were calculated based on a crossvalidation of at least two sources. Because spatial variables were not included in the CSHOD, the authors searched for information that would allow for geocoding of the places of the SHO's crimes. For example, a search of the list of references in Kerr (2011), revealed the existence of twenty-four cases with spatial identification of the location of the crimes. The authors repeated this process of gathering information until the appropriate data was obtained for all SHOs

. For the purposes of this study, the offender model was identified as marauder and commuter. Marauders are offenders who have a fixed starting point and commit their crimes near this starting point (immediate living environment). Commuters, however, do not have a fixed starting point when committing their crimes, as they travel to a particular area and determine from there where they will commit their crime. The proposed distinction between marauders and commuters arose originally from Canter and Larkin (1993) model of the spatial behavior of criminals during the execution of serial offences. The process of classifying an offender as either a marauder or commuter is automated by calculating the relationship between the maximum distance between the crime incidents and the offender's anchor point and the maximum distance between the two furthest crime incidents using the following equation;

$$OffenderModel = \frac{d_{cr}}{d_{cc}}$$

where d_{cr} is the distance from the farthest crime to the offender's residence and d_{cc} is the furthest distance between criminal incidents. The offender was categorized as a marauder if the ratio was less than 1.0 or a commuter if the ratio was equal or greater than 1.0 (Kent and Leitner 2007). The average number of victims ranged from 4 to 20. Based on $OffenderModel = d_{cr} / d_{cc}$ observed travel behavior, 71.8% of murderers are marauders and 28.2% are travelers.

Procedure for Each Geographic Profile Strategy

The comparative evaluation of the circular profiles of Newton, Gang, and the ellipticals of Levine were carried out in three phases. First, the crime scenes and the SHO's homes

were organized according to their status as either a commuter or a marauder. Second, to achieve the analysis method, the mathematical model (Figs. 1, 2 and 3) was implemented using the Scripting language in Python for a QGIS environment (QGIS Geographic Information System 2020). The circle hypothesis was run from the second series, creating a map displaying an area where the residence of an ofender is likely to be located. This search area focuses on the geographic center (geometric mean) in the case of Newton's model and between the distances of each series in the Gang model. As each new crime scene is incorporated into the standard procedure, the points obtained are processed again, adjusting the search area, changing position, and recalibrating the dimension of the circle.

In relation to the profile based on the standard deviation ellipse, we decided to choose Levine (2006) where there are corrections for degrees of freedom with a square root of 2, and a polygon vector layer with the standard deviation ellipse is produced. The process begins with an elliptical search area of variable size centered on the geographic center of a distribution, sequentially determined by the variance calculated on the minor and major axes. In each process that a new criminal incident is incorporated, the geographic center is recalculated, which adjust and reposition the ellipse to the profile. In the third stage of the process, the generated geometric figures are superimposed (i.e., ellipses, circles) where the area in which they converge indicates the existence of a subset that has characteristics that are common to them; in the remaining area, characteristic of each figure, the elements that belong only to this one are located. Since the crimes are related, there is a high probability that one of the overlapping areas is the anchor point (Rossmo 2000) with the highest probability being in the region where the circles intersect (Van Der Kemp 2014).

Measuring the Accuracy of Geographic Profiling Strategies

To analyze and evaluate the results, we followed the methodology of the NIJ expert panel (Rich and Shively 2005). Although the report reviewed several measures for evaluating geographic profiles, some of these measures were found to be controversial (Levine 2005; Rossmo 2005). However, there is currently no one standard for measuring performance




Fig. 4 Model ELLIPSE measuring the accuracy of geographic profiling strategies. Prepared by the author.

(Rich and Shively 2004). Based on their applicability to this study, three of the performance measures listed in the NIJ report were chosen to compare the efficacy of circular and elliptical model output: profile accuracy, profile error distance, and profile search area score (Kent and Leitner 2007). Profile accuracy is a binary test of whether the actual location of the offender's residence is within the upper profile region and is reported as "yes or no." Profile error distance is a modified measure that involves taking the Euclidean distance (defined as the square root of the sum of squares of the difference of each attribute of the two elements) between the known address to the nearest axis of the final expected search area of a profile (i.e., the area of greatest overlap) where shorter distances indicate better results. The strength of this measurement goes beyond a simple dichotomous measure of the profile accuracy as it ascertains the usefulness of the profile area. In providing a measure of how far the upper profile area is from the actual location of the offender, the profile search area score is a measure which indicates how much of the required search area was predicted by the model. The score was measured as the ratio of the predicted search area (i.e., modeled output) to the required search area (i.e., theoretical search area needed to encompass the offender's residence). To calculate the required search area, the top profile output was scaled until its outer edge intersected the offender's residence. The resulting ratio provided a relative measure of search cost where higher scores values indicate more accurate profile output. Although obtaining a proportion measure relative to the search came at the detriment of being able to determine values with higher scores, the process yielded a more precise profile (Fig. 4) (Kent and Leitner 2007).

Results

Profile Accuracy

The accuracy of the profile was judged based on whether the location of the anchor point geographically coincided with a profile's intended search area, defined as the area of maximum overlap. The cases that are within the region of maximum overlap are detailed in Table 1. The elliptical geographic profiles were accurate for 32 of 84 (38.09%) series in the case of marauding SHOs. Gang's circular model performed equally well, accurately predicting 17 of 84 (23.80%) series for marauding SHOs. The performance observed for the three models with traveling criminals has been very low 8 of 84 (9.52%). Of those predictions, only one model (5.95%) predicted the anchor point of 5 offenders in the final search area. With a 44.04% accuracy rate, the elliptical model shows a definite improvement in the technique's ability to predict an offender's anchor point.

Profile Error Distance

Table 2 provides descriptive information about the different profile models analyzed, the profile search area, and the error distance for each type of offending model (commuter-marauder). In the present research, the mean would be a questionable statistic to report in the current context, since the distributions are highly skewed. Interquartile ranges (IQR) were reported to provide an indication of data distribution around the median, which offer a vision of the data in the distribution. The means are reported for reference purposes for use in meta-analysis by other researchers.

The results of the error distance of the profile of Table 2 indicate that the behavior of the ellipse model is the most optimal, offering the shortest distances in the cases of marauder and commuter (1.65 km and 4 km, respectively).

Table 1 Profile accuracy (marauder-commuter)

Profile model <i>N</i> = 84	Commuter profile accuracy	Marauder profile accuracy
Gang	3 (3.57%)	17 (23.80%)
Ellipse	5 (5.95%)	32 (38.09%)
Newton	0 (0.00%)	9 (10.71%)

Table 2 Profile model summary results

Profile model	Profile search area km ² [Commuter] N:23		Profile search area km ² [Marauder] N:61		Profile error distance km [Marauder] N:61		Profile error distance km [Commuter] N:23	
	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)	Mean (SD) [Min–Max]	Median (IQR)
Gang	0.216 (0.383) [0.008–1.32]	0.012 (0.003–0.23)	7.05 (48.72) [0–381.2]	0.244 (0.02–1.34)	13.47 (45.04) [0.77–331.7]	2.63 (0.8–4.3)	51.28 (106.9) [0.24–452.3]	9.5 (2.9–22.3)
Ellipse 1 (SD)	0.550 (0.665) [0–2.21]	0.279 (0.030–0.65)	8.16 (25.3) [0–166.6]	0.973 (0.19–3.38)	11.52 (32.02) [0.11–208.9]	1.65 (0.6–4.5)	31.42 (71.22) [0.42–273]	4 (1.8–9.8)
Newton	0.023 (0.037) [0.050–0.15]	0.006 (0.001–0.036)	0.81 (2.04) [0.2–9.76]	0.065 (0.010–0.029)	18.10 (33.21) [1–168.9]	5.09 (1.7–16)	73.38 (138) [2.3–597.3]	12.22 (5.9–50.7)

However, Gang’s circular model (with a distance score of 2.63 km for marauders was only 0.98 km shorter than that for ellipses) has behaved with a substantial difference to Newton’s circular model with a score of 5.09 km. The marauding criminals obtained shorter profile error distances in the three models analyzed.

For this evaluation technique, the Friedman test compared and classified the measured error distances for each model (Table 3).

The lowest mean range difference of 1.74 and 1.3 was assigned to the marauders and commuters, respectively, in the ellipse 1 (SD) model, indicating better performance. The error distances for this model were frequently shorter than those produced by the circular models. In contrast, Newton’s circular model ranked last in comparisons (range=2.38 and 2.6) for marauders and commuters, indicating that this technique, on average, produced error distances that were often greater compared to the other models.

Friedman’s test for samples related to K indicate that there are statistically significant differences in the profile error distances between the models (chi-square=10.87, df=2, < p 0.004) in the case of marauders and (chi-square=22.26, df= 2, p 0.001) for commuters. Importantly, these differences are largely due to significant differences in the size of the overlapping area of the upper profiles (chi-square=24,255, df=2,p<0.0001) in marauders and (chi-square= 18,348, df=2, p 0.0001) in commuters and their subsequent impact on the profile error distance.

To improve the comparisons between measures, we have also conducted some pairwise comparisons through a non-parametric technique called the one-sided Wilcoxon signed-rank test. This test determines if an algorithm is significantly better than another by comparing their results on all the datasets at a confidence level $\alpha=0.05$. Pairwise

comparisons in Table 4 represent the number of times that a particular model produced the shortest (best), furthest (worst), or equal (tie) error distance compared to all other estimates. The ellipse model (SD1) obtained a higher performance with more estimates with equal or shorter error distances than those produced by the other techniques (in the case of the Gang 53 circular (63.09%) and in the case of Newton 63 (75%)).

In terms of the test data, however, there is no statistically significant difference in the distributions of distance errors

Table 3 Friedman test statistics

	Profile search area [Commuter] Friedman rank (A)	Profile search area [Marauder] Friedman rank (B)	Error distance [Marauder] Friedman rank (C)	Error distance [Commuter] Friedman rank (D)
Gang	1.95	1.85	1.92	2.0
Ellipse 1 (SD)	2.65	2.50	1.74	1.3
Newton	1.39	1.64	2.38	2.6

Friedman test statistics, $N=84$, $\alpha=0.05$, commuter $N=23$, marauder = 61

(a) $X.^2=18.348$, $df=2$, $p<0.0001$

(b) $X.^2=24.255$, $df=2$, $p<0.0001$

(c) $X.^2=10.87$, $df=2$, $p=0.004$

(d) $X.^2=22.26$, $df=2$, $p<0.0001$

Table 4 Wilcoxon signed-rank test for pairwise comparisons of modeled error distance

	Gang and ellipse	Gang and Newton	Ellipse and Newton	Sum
Combined results: Z	-2.252	-3.679	-4.875	
Asymp. sig (2-tailed)	0.024	0.000	0.000	
Success	31	57	63	151
Failure	52	27	21	100
Tie	1	0	0	1
Commuter results: Z	-2.646	-2.677	-3.528	
Asymp. sig (2-tailed)	0.008	0.007	0.000	
Success	5	18	21	44
Failure	18	5	2	25
Tie	0	0	0	0
Marauder results: Z	-0.920	-2.575	-3.358	
Asymp. sig (2-tailed)	0.357	0.010	0.001	
Success	26	39	42	107
Failure	34	22	19	75
Tie	1	0	0	1

between the Gang and ellipse models (SD1) when looking at the ofender model (marauders) (Wilcoxon signed-ranks test, $p=0.357$, Asymp. sig (2-tailed). Therefore, the hypothesis that the distribution of the two samples is the same in favor of the alternative hypothesis cannot be rejected.

Profile Search Area Score

Elliptical models again outperformed the circular model (see Table 3). However, it was not found that the difference between the marauding delinquent classification and the Gang and Newton circular profile was significantly different according to the Wilcoxon signed rank test ($Z= -1.706$, $p < 0.088$) (Table 5).

Individual comparisons for each evaluation technique are provided in Tables 4 and 5. These tables detail how often a model worked compared to other techniques. The results were compared using non-parametric tests. The Friedman test was applied to the entire group and was used to determine if the modeled result was different for each measure.

The results of the Friedman test for samples related to K indicate that there are statistically significant differences in the profile search area score between the methods (chi-square=18,348, $df=2$, $p < 0.001$) for commuter and

Table 5 Wilcoxon signed-rank test for pairwise comparisons of modeled profile probability profile search area score

	Gang and ellipse	Gang and Newton	Ellipse and Newton	Sum
Combined results: Z	-4.567	-2.564	-5.945	
Asymp. Sig (2-tailed)	0.000	0.010	0.000	
Success	61	33	15	109
Failure	23	51	69	143
Tile	0	0	0	0
Commuter results: Z	-3.346	-2.585	-4.045	
Asymp. Sig (2-tailed)	0.001	0.010	0.000	
Success	17	7	2	26
Failure	6	16	21	43
Tile	0	0	0	0
Marauder results: Z	-3.595	-1.706	-4.816	
Asymp. Sig (2-tailed)	0.000	0.088	0.000	83
Success	44	26	13	100
Failure	17	35	48	0
Tile	0	0	0	

$\alpha=0.05$

(chi-square=24,255, df=2, p 0.0001) for marauder. The p-value indicates that the probability of rejecting the null hypothesis, even if it is true, is less than 0.0001. In that case, we conclude that we can safely reject the null hypothesis and that there is no difference between the profile search area scores.

Discussion

The aim of the present study is to analyze three dispersion distribution strategies to build a geographic profile model on the basis of set theory that can determine the best performance of the model and measure the theoretical and operational effectiveness in LEOs.

In practical terms, the accuracy of the profile error distance measurement has been balanced by overlapping with the size of the average upper profile area, relative to the total areas of the circular and elliptical models. Specifically, as the area of the upper profile becomes larger, the measure of the profile error distance will decrease while simultaneously becoming less useful in reducing the area of the crime domain during an investigation. Although these search areas may not be as large as those derived from the circle hypothesis (Canter and Larkin 1993), such reference areas have been reduced enough to allow LEOs to initiate a search. In this sense, the upper profile areas have been

minimized by incorporating in the dispersion strategy models and the maximum overlap of the resulting geometries. The Venn diagram model has been significantly improved by minimizing the search areas associated with estimating the home of a marauding SHO. However, there are some disadvantages to the Venn diagram method, in those series where not all circles overlap (Bots 2010; Captein 2009) or in those repeated areas with maximum overlap. Following the line of work of Canter et al. (2013) in both disadvantages, the smaller area has been used to define the area of maximum overlap.

One primary finding of the present study is that the elliptical model performed better than circular models, with a 44.04% profile coincidence with the search area. The present research demonstrates that the largest area of the orientation of the elliptical models representing one standard deviation (SD) of the distance from the center of the geometric mean matches the direction and shape of the crime scene patterns more accurately. In the case of the marauders, no significant differences were found in the distances of the elliptical model and the variable distance Gang circular model. No significant differences were found in the profile search area scores in the circular models. These findings point to important differences between the delinquent models and in the choice of the profile model. While elliptical models may be the most accurate in terms of profile error distance, it can be practically less useful than the Gang circular model since it has a much smaller average upper profile area and only a slightly less accurate profile error distance measurement. The accuracy of the method against travelers was poor. This is in line with Levine's conclusions based on his validity test for criminals who do not live in the center of their distribution (Levine 2014).

The results of the present study are in line with much of the journey to crime studies that have shown that different types of offenders differ in the distances they travel (Canter and Hammond 2006; Canter and Gregory 1994; Capone and Nichols 1976; Hammond and Youngs 2011). Because the present study employed data from a large span of time, beginning in 1929, it stands to reason that many aspects of society have evolved since then, namely transportation methods and geographic boundaries. By not using functional distances, such as those used in some cases in probability distance strategies, these changes to society have little impact on the exploration of nodes and routes in the framework of the so-called journey to crime.

We recommend that LEOs work to develop methods to determine in advance whether or not a series involves a traveler or a marauder and establish procedures to

handle both types of cases. It is also possible to consider more aspects in geographic analysis than just the factor of distance and take those aspects into account in calculations. Some authors attempt to account for directional effects or assign weights to certain crime scenes even though the underlying assumptions on the basis of which they report are based on moderate evidence or are simply not explicit (Godwin 2000; Rossmo 2000).

Limitations

There are several limitations to the present study. First, the proposed methodology assumes an isotropic surface where the obstacles are uniform in all directions. As a consequence, these models do not adapt to the inherent variations exhibited by a particular transport network, such as route, direction, speed, landscape features, and urban development when executing the algorithms. Although this is consistent with current probabilistic profiling models that assume an isotropic surface where the spatial impedances are uniform in all directions, few methods include geographic actors (functional distances) in their geographic profiling analysis as a variable that influences the offender's spatial behavior. For that reason, it is necessary to determine how to calibrate the methodology for specific jurisdictions. Second, although the aim of the present study is to increase the knowledge about the special relationships of those involved and facilitate the development of typologies of events, it was limited in that the offender's data cannot be known at the beginning of the process. Third, the corresponding average travel distance is not yet known for each crime (Bots 2010) and that several areas may arise where the same amount of overlap can be seen.

The solution to the calibration of the superimposed circles model was proposed by Van Koppen et al. (2000) and calculates all distances between the home and crime locations for each known offender, crime type, and geographic area. The median of these distances is then calculated which results in the operating range of all offenders within that geographic area. The radius is the average distance that is applied to other perpetrators of solved crimes of the same crime type in a similar environment (Beijsterveldt 2006) and, therefore, may vary depending on the crime type. As a result, a larger or smaller overlap area is obtained as the search area. The point where all the circles overlap is the point or area where the perpetrator likely resides (Van Koppen et al. 2001, 2002). This method may have been applicable to the present research as it is based on empirical data of the

travel distances of offenders for various crimes and because the radius of the circles around the crime scenes can be adjusted (Van Koppen et al. 2002), but it is not yet known what the corresponding average travel distance is for each crime (Bots 2010) which is why this methodology was not utilized for the present study.

Implications and Conclusions

Although spatial issues and mobility among criminals is well established in the literature, the present study sought to deepen its understanding using a sample of SHOs. Tita and Griffiths (2005) argue that many homicides involve movement as victims and offenders interact in both time and space. This mobility is associated with event characteristics as opposed to characteristics of either the offender or victim. The empirical evidence from spatial behavior analysis highlights the importance of these situational factors in the serial offender's decision-making (Beauregard and Leclerc 2007; Deslauriers-Varin and Beauregard 2014) as they take into account the risks of approaching their victims and must consider, among other factors, the current place and the present moment (Hewitt and Beauregard 2014). Another approach to the analysis of the mobility of offenders that aims to better understand the convergence of offenders and victims in the same space–time coordinates consists of the so-called “mobility triangles” (Grof and McEwen 2007). This is a strategy that allows for the examination of the offender's mobility in terms of the relative position of their residence, the victim, and the crime scene which creates a triangle.

To the extent that we are able to establish a relationship between crime patterns and geometry, the presence of certain key characteristics, as well as the distance between the series, may become indicators of interest and raise hypotheses. The proposed methodology could be applied by LEOs that do not have the commercial tools necessary to generate probability distance strategies. From the point of view of academic research, the present study provides a vision and a work methodology to deepen the understanding of the mobility patterns of SHOs and can also be extrapolated to other criminal typologies.

In summary, the principles of distance decay, crime-free zones, and direction of travel do not appear to add value to the results of geographic offender profiling. In essence, the simplest technique for determining a SHO's geographic profile (i.e., the circle technique) is as effective as the more complicated techniques (Lopez 2017). The use of

simpler strategies is consistent with several studies, such as that of Snook (2000), in which students with no prior knowledge of geographic profiling of offenders were able to make judgments based on two decision rules as accurate as the results using probability distribution strategies. This does not mean that approaches using more complicated techniques should now be discarded a priori. The effectiveness of geographic profiling of SHOs is not determined solely by the technique chosen, but primarily by the way in which the technique is applied by geographic profilers and within LEOs. In this sense, the better the coordination of geographic profiling of SHOs with other forms of information and/or methods of offender detection, the greater its practical utility.

Due to its complex nature, attempting to connect multiple locations with SHOs using geographical analysis is often challenging. Future studies should consider these challenges, such as how the SHO's cooling-of period and its relationship with distance complicates the process and takes those issues into account in calculations. Future research should interrogate Kim, Chun, and Gould (2013) framework for understanding homicide from a sociogeographic perspective using a Geographic Information System as it is not currently known to what extent these techniques behave in the dispersion distribution models. In the end, the present research introduces a set of ideas that researchers, geographic profilers, and LEOs can review when searching for a simpler and cost-effective alternative to current practices. We support further research in this area and offer the present study to inspire others to carry forward such work. The present study advocates for the use of the simplest technique for determining a SHO's geographic profile in the hopes of lessening the impact that SHOs have on society.

Appendix

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
1	Kenneth	Bianchi	USA	8	10/1977–1/1979	General public, female
2	Donato	Bilancia	Italy	5	10/1997–4/1998	General public, male/female
3	David	Birnie	Australia	4	10/1986–11/1986	General public, female
4	Robert	Black	Northern Ireland, England, Scotland	4	8/1978–3/1986	General public, female children
5	Ian	Brady	England	5	7/12/1963–10/6/1965	General public, male/female
6	Dean	Carter	USA	4	1984–1984	Home invasion, female
7	Jeffrey	Dahmer	USA	5	6/18/1978–7/19/1991	Sex workers, male
8	Albert	Desalvo	USA	13	6/14/1962–1/4/1964	General public, female
9	Sipho	Dube	South Africa	6	2001–11/8/2003	General public, children
10	Marc	Dutroux	Belgium	4	8/22/1995–1996	General public, female
11	Cristopher	Dwayne	USA	7	10/30/1990–12/8/1990	General public
12	Kenneth	Erskine	England	6	4/9/1986–7/23/1986	Home invasion, elderly females
13	Cordell	Farrington	Bahamas	4	5/16/2003–9/28/2003	General public, male children
14	Lorenzo	Fayne	USA	6	7/14/1989–7/24/1993	General public, female children
15	Joaquin	Ferrandiz	Spain	5	7/2/1995–9/14/1996	Female
16	Danny	Figueroa	USA	4	5/13/1986–6/17/1986	General public
17	Roy	Fontain	England	5	9/01/1977–1/16/1978	General public
18	Michel	Fourniret	France	8	12/11/1987–5/5/2001	General public, female
19	Ferdinand	Gamper	Italy	4	2/8/1996–3/1/1996	General public
20	John	Glover	Australia	6	3/1/1989–11/24/1989	General public, female
21	Steven	Grieverson	England	4	5/26/1990–4/25/1994	General public, male children
22	John	Haigh	England	4	9/6/1944–2/18/1949	Acquaintances
23	Leslie	Irvin	USA	4	12/2/1954–3/28/1955	Employees
24	Shantaram	Jagtap	India	5	1/16/1976–3/23/1977	Home invasion, males and females
25	Vincent	Johnson	USA	6	8/26/1999–6/7/2000	Sex workers, female
26	Anthony	Kirkland	USA	4	5/20/1987–3/7/2009	General public, female
27	Joachim	Kroll	Germany	9	2/8/1955–7/3/1976	General public, male/female
28	Peter	Kurten	Germany	5	2/8/1929–11/7/1929	General public, male children

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
29	Cesar	Legorreta	Mexico	7	7/14/2011–1/18/2012	General public, female
30	Bobby	Long	USA	9	3/27/1984–11/11/1984	Sex workers, female
31	John	Lovgren	Sweden	4	6/27/1957–9/2/1963	Home invasion, female
32	Michael	Lupo	England	4	3/15/1986–4/24/1986	Sex workers
33	Matthew	Macon	USA	6	12/20/2004–8/29/2007	Home invasion, females
34	Peter	Manuel	Scotland	5	1/2/1956–1/1/1958	Home invasion, males and females
35	Raymond	Morris	England	4	9/8/1965–8/19/1967	General public, female children
36	Tsutomu	Miyazaki	Japan	4	8/22/1988–6/6/1989	General public, female children
37	Pedro	Nakada	Peru	13	1/1/2005–12/27/2006	Homeless
38	Donald	Neilson	England	4	2/15/1974–1/14/1975	General public
39	Itzcoatl	Ocampo	USA	4	10/25/2011–1/13/2012	Homeless
40	Clifford	Olson	Canada	11	11/17/1980–7/30/1981	General public, children
41	Antonio	Ortiz	USA	4	5/24/1997–7/26/2000	General public, female children
42	Pietro	Pacciani	Italy	5	8/21/1968–9/8/1985	General public
43	Somkhid	Phumphuang	Thailand	5	1/30/2005–6/21/2005	Sex workers, female
44	Larme	Price	USA	4	2/8/2003–3/20/2003	Employees
45	George	Putt	USA	4	8/14/1969–9/11/1969	Home invasion, males and females
46	Charles	Quansah	Ghana	20	1993–2000	General public, female
47	Larry	Ralston	USA	5	9/3/1975–10/22/1977	General public, female
48	Richard	Ramirez	USA	15	6/28/1984–8/8/1985	Home invasion
49	Andre	Rand	USA	4	7/7/1972–7/9/1987	General public, female children
50	Robert	Reldan	USA	5	8/10/1974–10/24/1975	General public, female children
51	Angel	Resendiz	USA	6	1986–6/15/1999	Home invasion, females
52	Joel	Rifkin	USA	13	1989–6/24/1993	Sex workers, females
53	Michael	Ross	USA	7	5/12/1981–6/13/1984	General public, females
54	Alexander	Rubel	Estonia	7	9/19/1997–6/4/1998	General public
55	Remedios	Sanchez	Spain	8	6/10/2006–7/3/2006	Female
56	Viktor	Sayenko	Ukraine	7	6/25/2007–7/16/2007	General public
57	Manfred	Seel	Germany	5	2/6/1971–4/1/2004	Female
58	Munawar	Shah	India	5	1/16/1976–3/23/1977	Home invasion, male and female
59	Robert	Shulman	USA	5	8/1/1991–12/8/1995	Sex workers, female

Offender	First name	Last name	Country	Number of crimes reviewed	Span of crimes	Victim type
60	Darbara	Singh	India	11	8/15/2004–10/25/2004	General public, female children
61	Mark	Smith	South Korea/ Germany/USA	4	3/12/1969–5/27/1970	General public, female
62	Peter	Sutcliffe	England	20	10/30/1975–11/17/1980	General public, female
63	Joseph	Taborsky	USA	7	3/23/1950–1/26/1957	Employees/ customers
64	Kevin	Taylor	USA	4	6/25/2001–8/18/2001	Sex workers, female
65	Richard	Trenton	USA	4	12/29/1977–1/27/1978	General public
66	Helmut	Weidenbrocker	Germany	5	4/05/1982–6/03/1986	Female
67	Rosemary	West	England	8	6/18/1971–6/19/1987	Multiple types
68	John	Williams	USA	6	1/7/1996–12/24/1996	Sex workers, female
69	Carl	Williams	Australia	5	6/15/2000–3/21/2004	Criminals
70	Michael	Wolter	Germany	8	5/7/1980–11/26/1982	General public
71	Steven	Wright	England	5	10/30/2006–12/11/2006	Sex workers, female
72	Robert	Yates	USA	11	7/13/1975–10/13/1998	Sex workers, female
73	Alfredo	Galan	Spain	5	1/4/2003–3/18/2003	General public
74	Francisco	Escalero	Spain	11	8/1/1987–4/1/1994	Homeless
75	Waldo	Grant	USA	4	9/14/1973–12/29/1976	Homosexual males
76	Colin	Ireland	England	5	3/8/1993–6/15/1993	Sex workers
77	Edmund	Kemper	USA	6	8/27/1964–4/21/1973	Hitchhikers
78	Joachim	Knychal	Poland	5	03/11/1974–5/8/1982	Female
79	William	Macdonald	Australia	5	1/6/1961–11/4/1962	Homeless
80	Lazarus	Mazingane	South Africa	16	4/13/1993–4/23/1998	General public, female
81	Vinko	Pintaric	Croatia	5	4/26/1973–8/2/1990	General public, male/female
82	Reinaldo	Rivera	USA	4	7/17/1999–9/29/2000	General public, female
83	Wolfgang	Schmidt	Germany	5	10/24/1989–4/5/1991	General public, female
84	Roberto	Arguelles	USA	4	2/21/1992–3/30/1992	General public, female

Data Availability The datasets generated during and/or analysed during the current study are available in the Harvard Dataverse repository, https://dataverse.harvard.edu/dataverse/serial_homicide.

Referencias

Aamodt, M., Fox, J. A., Hickey, E., Hinch, R., Labuschagne, G., Levin, J., McClellan, J., Nelson, B., Newton, M., Quinet, K., Steiger, C., White, J., & Yaksic, E. (2022). Consolidated Serial Homicide Offender Database. https://dataverse.harvard.edu/dataverse/serial_homicide

Adjorlolo, S., & Chan, H. C. (2014). The controversy of defining serial murder: Revisited. *Aggression and Violent Behavior*, 19(5):486–491. <https://doi.org/10.1016/j.avb.2014.07.003>

Beauregard, E., & Leclerc, B. (2007). An application of the rational choice approach to the offending process of sex offenders: A closer look at the decision-making.

Sexual Abuse: A Journal of Research and Treatment. 19(2):115-133.
<https://doi.org/10.1177/107906320701900204>

- Beijsterveldt, K. van. (2006). Traveler or poacher?: Geographic offender profiling and travel patterns of property crime offenders. Rotterdam: Erasmus Universiteit (Master Thesis).
- Bots, K. (2010). The Performance of the Circular Method of Van Koppen, De Poot and Van Koppen. Comparison with two techniques of Geographic Offender Profiling. Amsterdam Vrije Universiteit.
- Brantingham, P. J., & Brantingham, P. L. (1981). Environmental Criminology. Beverly Hills, CA: Sage Publications.
- Canter, D., & Hammond, L. (2006). A comparison of the efficacy of different decay functions in geographical profiling for a sample of US serial killers. *Journal of Investigative Psychology and Offender Profiling*. 3(2):91–103.
<https://doi.org/10.1002/jip.45>
- Canter, D., Hammond, L., & Juszcak, P. (2013). The Efficacy of Ideographic Models for Geographical Offender Profiling. 29(3):423–446.
<https://doi.org/10.1007/s10940-012-9186-6>
- Canter, D., & Larkin, P. (1993). The environmental range of serial rapists. *Journal of Environmental Psychology*. 13(1):63–69. [https://doi.org/10.1016/S0272-4944\(05\)80215-4](https://doi.org/10.1016/S0272-4944(05)80215-4)
- Canter, D., & Gregory, A. (1994). Identifying the residential location of rapists. *Journal of the Forensic Science Society*. 34(3):169–175. [https://doi.org/10.1016/S0015-7368\(94\)72910-8](https://doi.org/10.1016/S0015-7368(94)72910-8)
- Cantor, G. (1915). Cantor Contributions to the Theory of Transfinite Numbers.
- Capone, D. L., & Nichols, W. W. (1976). Urban Structure and Criminal Mobility. *American Behavioral Scientist*. 20(2):199–213.
<https://doi.org/10.1177/000276427602000203>
- Captein, M. (2009). Geographic offender profiling within the RPAA.
- DeLisi, M., & Scherer, A. M. (2006). Multiple Homicide Offenders: Offense Characteristics, Social Correlates, and Criminal Careers. *Criminal Justice and Behavior*. 33(3):367–391. <https://doi.org/10.1177/0093854806286193>
- Deslauriers-Varin, N., & Beauregard, E. (2014). Consistency in crime site selection: An investigation of crime sites used by serial sex offenders across crime series. *Journal of Criminal Justice*. 42(2):123-133.
<https://doi.org/10.1016/j.jcrimjus.2013.09.005>
- Ebdon, D. (1988). *Statistics in Geography*. Oxford, Blackwell.

- Edelstein, A. (2019). Cooling-Off Periods among Serial Killers. *Journal of Psychology & Behavior Research*. 2(1):1-15. <https://doi.org/10.22158/jpbr.v2n1p1>
- Gang, J., Dai, Q., & Li, S. (2014). Prediction Model for Law Enforcement Agencies on the Serial Criminals. *Journal of Applied Science and Engineering Innovation*. 1(5):316–323.
- Garrido, V., & Sobral, J. (2008). *Criminal investigation: psychology applied to the discovery, capture and conviction of criminals*. Nabla.
- Godwin, G. M. (2001). *Criminal Psychology and Forensic Technology*. (G. M. Godwin (ed.); CRC Press). <http://www.investigativepsych.com>.
- Groff, E. R., & McEwen, T. (2007). Integrating distance into mobility triangle typologies. *Social Science Computer Review*. 25(2):210-238. <https://doi.org/10.1177/0894439307298924>
- Hammond, L., & Youngs, D. (2011). Decay functions and criminal spatial processes: Geographical offender profiling of volume crime. *Journal of Investigative Psychology and Offender Profiling*. 8(1):90–102. <https://doi.org/10.1002/jip.132>
- Hewitt, A., & Beauregard, E. (2014). Sexual crime and place: The impact of the environmental context on sexual assault outcomes. *Journal of Criminal Justice*. 42(5): 375-383. <https://doi.org/10.1016/j.jcrimjus.2014.05.003>
- Hodgkinson, S., & Tilley, N. (2007). Policing Anti-Social Behaviour: Constraints, Dilemmas and Opportunities. *The Howard Journal of Criminal Justice*. 46(4):385-400. <https://doi.org/10.1111/j.1468-2311.2007.00484.x>
- Kent, J., Leitner, M., & Curtis, A. (2006). Evaluating the usefulness of functional distance measures when calibrating journey-to-crime distance decay functions. *Computers, Environment and Urban Systems*, 30(2):181-200. <https://doi.org/10.1016/j.compenvurbsys.2004.10.002>
- Kent, J., & Leitner, M. (2007). Efficacy of Standard Deviation Ellipses in the Application of Criminal Geographic Profiling. *Journal of Investigative Psychology and Offender Profiling*. 165:147–165. <https://doi.org/10.1002/jip.72>
- Kerr, G. (2011). *Mapping the Trail of a Crime: How Experts Use Geographic Profiling to Solve the World's Most Notorious cases* (Readers Digest (Ed.)).
- Kim, H., Chun, Y., & Gould, C. A. (2013). Crime Scene Locations in Criminal Homicides: A Spatial Crime Analysis in a GIS Environment. In *Crime Modeling and Mapping Using Geospatial Technologies*. Springer, Dordrecht.
- Leitner, M., Kent, J., Oldfield, I., & Swoope, E. (2007). Geoforensic Analysis Revisited—The Application of Newton's Geographic Profiling Method to Serial Burglaries in London, UK. *Police Practice and Research*. 8(4):359–370. <https://doi.org/10.1080/15614260701615060>

- Levine, N. (1999). CrimeStat Program Description. 1–65.
- Levine, N. (2005). Response to Kim Rossmo Critique of the GP Evaluation Methodology. <http://www.nedlevine.com/Response%20to%20Kim%20Rossmo%20Critique%20of%20the%20GP%20Evaluation%20Methodology.May%208%202005.doc>.
- Levine, N. (2006). Crime mapping and the CrimeStat program. *Geographical Analysis*, 38(1):41–56. <https://doi.org/10.1111/j.0016-7363.2005.00673.x>
- Levine, N. (2014). Journey-to-Crime Estimation. <https://www.semanticscholar.org/paper/Chapter-13-%3A-Journey-to-Crime-Estimation-Levine/5e95cde24d172530ebc965c8412e84ef02aa193a>.
- Lopez, M. (2017). Geographic Offender Profiling. Result Crime Management. <https://doi.org/10.13140/RG.2.2.28187.26408>
- Lopez, M. J. J. (2005). The spatial behavior of residential burglars. Proceedings of the 5th International Space Syntax Symposium. TU Delft, Techne Press, Delft.
- Lundrigan, S., Czarnomski, S., & Wilson, M. (2010). Spatial and environmental consistency in serial sexual assault. *Journal of Investigative Psychology and Offender Profiling*, 7(1):15-30. <https://doi.org/10.1002/jip.100>
- Newton, M. B. (1988). Geographical discovery of the residence of an unknown dispersing localized serial murder. Unpublished manuscript, Louisiana State University, Baton Rouge, LA.
- Paulsen, D. (2006). Human versus machine: a comparison of the accuracy of geographic profiling methods. *Journal of Investigative Psychology and Offender Profiling*, 3(2):77–89. <https://doi.org/10.1002/jip.46>
- QGIS Geographic Information System. (2020) Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>.
- Rich, T., & Shively, M. (2005). A Methodology for Evaluating Geographic Profiling Software. 1–259. <https://www.ncjrs.gov/pdffiles1/nij/grants/208993.pdf>.
- Rossmo, D. K. (2000). *Geographic profiling*. Boca Raton, FL: CRC Press.
- Salafranca, D. (2021). The application of Newton and Swoope’s geographical profile to serial killers. *Journal of Investigative Psychology and Offender Profiling*, 18(1):68-78. <https://doi.org/10.1002/jip.1566>
- Silva Silva, J. A. (2009). Set theory and Private International Law. *Mexican Comparative Law Bulletin*, 126:1463–1497.
- Simkin, M., & Roychowdhury, V. (2011). Re-inventing Willis. *Physics Reports*, 502(1):1-35.

- Snook, B., Canter, D., & Bennell, C. (2002). Predicting the home location of serial offenders: a preliminary comparison of the accuracy of human judges with a geographic profiling system. *Behavioral Sciences & the Law*. 20(1–2):109–118. <https://doi.org/10.1002/bsl.474>
- Snook, B., Taylor, P. J., & Bennell, C. (2004). Geographic profiling: the fast, frugal, and accurate way. *Applied Cognitive Psychology*. 18(1):105–121. <https://doi.org/10.1002/acp.956>
- Snook, B., Zito, M., Bennell, C., & Taylor, P. J. (2005). On the complexity and accuracy of geographic profiling strategies. *Journal of Quantitative Criminology*. 21(1):1–25. <https://doi.org/10.1007/s10940-004-1785-4>
- Tita, G., & Griffiths, E. (2005). Traveling to violence: The case for a mobility-based spatial typology of homicide. *Journal of Research in Crime and Delinquency*. 42(3):275-308. <https://doi.org/10.1177/0022427804270051>
- Van der Kemp, J. J. (2014). Mode via: Refinement of geographic offender profiling. <https://research.vu.nl/en/publications/modus-via-verfijning-van-geografische-daderprofilering>.
- Van Koppen, P. J., de Poot, C. J., & van Koppen, M. (2000). Circles of Crimes. About the places where crimes were committed and the place of residence of the perpetrators. *The Psychologist*. 35(10):435–442.
- Van Koppen, P. J., De Poot, C. J., & Van Koppen, M. V. (2001). Identifying the domiciles of the offender: Geographic offender profiling in practice. *Balaclava, Police Hat, and Gown: Interplay between Crime and Law Enforcement*. 79-98.
- Van Koppen, P. J., Van der Kemp, J. J., & De Poot, C. J. (2002). *Geographic Offender Profiling. The Right Inside: Psychology of Law*. Kluwer.
- Yaksic, E. (2015). Addressing the challenges and limitations of utilizing data to study serial homicide. *Crime Psychology Review*. 1(1):108-134. <https://doi.org/10.1080/23744006.2016.1168597>
- Yaksic, E. (2018). The Folly of Counting Bodies: Using regression to transgress the state of serial murder classification systems. *Aggression and Violent Behavior*. 43:26-32. <https://doi.org/10.1016/j.avb.2018.08.007>
- Yaksic, E. (2019). Moving past sporadic eruptions, discursive killing, and running amok: recognizing the convergence of the serial and spree killer: Recognizing the convergence of the serial and spree killer. *Journal of Criminal Psychology*. 9(3):138–146. <https://doi.org/10.1108/JCP-03-2019-0009>
- Yaksic, E., Simkin, M., & Roychowdhury, V. (2021). A statistical study of the time intervals between serial homicides. *Journal of Criminal Justice*. 73:1-10. <https://doi.org/10.1016/j.jcrimjus.2020.101751>

Yuill, R. S. (1971). The Standard Deviational Ellipse; An Updated Tool for Spatial Description. *Geografiska Annaler. Series B, Human Geography*. 53(1):28–39. <https://doi.org/10.2307/490885>

Zimmermann, H. J. (2001). Fuzzy set theory and its applications - Fourth Edition. In Kluwer, Boston, 2nd ed., 1993. <https://doi.org/10.1007/978-94-010-0646-0>

ANEXO E

INDICIO DE CALIDAD DE LA TESIS DOCTORAL

(ARTÍCULO CIENTÍFICO)

The application of Newton and Swoope's geographical profile to serial killers

Daniel Salafranca Barreda 

Crimina Center, University Miguel Hernández, Elche, Alicante, Spain

Correspondence

Daniel Salafranca Barreda, University Miguel Hernández, Av Universidad s/n. Edif. Hélike, Alicante 03202, Spain.
Email: d.salafranca@crimina.es

Abstract

Quite possibly, the first application of geographic analysis to identify and characterise the spatial behaviour of the offender concerning the crime scene was developed in 1980 by Milton Newton. Although previous studies have used Newton and Swoope's geoforensic process (Kent, 2009, *Essays on the integration of anisotropic landscapes within contemporary geographic profiling models* [LSU doctoral dissertations]; Leitner et al., 2007, *Police Practice and Research*, 8[4], 359–370) to verify the effectiveness of the algorithm, there are, to our knowledge, no investigations that have validated the procedure with cases of serial murderers. The main objective of the study is to analyse a sample of 41 serial killers with a minimum number of six crimes and to evaluate the method proposed by Newton (1988, *Geographical discovery of the residence of an unknown dispersing localized serial murder*). The results confirm only Newton's first assumption in which after the fifth crime in the series, the estimated 'haven' is close to the actual 'haven', ruling out that the search area becomes progressively smaller and that the 'haven' is located in the search area.

KEYWORDS

geoforensic analysis, geographic profiling, haven, serial killer, spatial dispersion

1 | INTRODUCTION

The model developed in the mid-1980s by Milton Newton, Professor of Geography at Louisiana State University, aims to identify and characterise the offender's spatial behaviour in relation to the crime scene (Newton & Swoope, 1987), the research that influenced later developed methods in geographic profiling (Kent et al., 2006). Today, this area of investigation is commonly known as geographic profiling, which is proposed as the main objective to obtain the offender's geographic behaviour or the location of the crime-related geographic context in the crime analysis process; it is generally used to speculate on the possibility of residence of criminals.

Newton's model is based on two major theories of crime, which forms the foundations of geographic profiling: routine activity theory developed by Cohen and Felson (1979) and rational choice theory classical, later articulated by leading criminologists (Cornish & Clarke, 1986; Nagin, 2007), which is based on these early classical approaches.

Unfortunately, the research in which Newton detailed this method was never published, and all references to his method are based on a presentation at the 1987 annual meeting of the American Academy of Forensic Sciences, San Diego, CA (Newton & Swoope, 1987), and in a manuscript that explains the theoretical and methodological foundations of the geoforensic process (Newton, 1988).

In the case, The Hillside Stranglers on which the presentation is based, he uses the geoforensic process in a retrospective analysis of the case of the murderer Angelo Bueno, estimating with greater precision the 'haven' of the murderer. Haven or anchor point can include such things as a residence, work, etc. A search radius was also calculated (circumscribing an area around the geographic centre in which the killers were believed to be located), the range of which decreased with the addition of spatial information provided for each new murder (D. K. Rossmo, 1997).

The objective of this research is to evaluate the performance of the geoforensic analysis model presented by Newton (1988) and provide an overview without a theoretical background of the application of the model applied to a sample of serial killers, both in the selected sample and in the assumptions presented by Newton (1988).

Following the line of the assumptions presented by Newton (1988), the three conditions of the proposed methodology will be analysed:

1. The estimated 'haven' approaches the actual 'haven' with each successive crime occurrence after the fifth crime in the series.
2. The search area gets smaller with each successive crime after the fifth crime.
3. The actual 'haven' falls within the search area after the fifth series.

2 | GEOGRAPHIC PROFILE STRATEGIES.

Geographic profilers have access to a repertoire of strategies (spatial distribution and probability distance) to predict the location of the anchor point or 'haven' as Newton calls it, of a serial offender. These strategies vary in complexity (some involve more calculations to implement than others) and the assumption that is often made is that more complex strategies will outperform simpler strategies. Although this assumption of 'complexity equals precision' has been questioned (Snook et al., 2002). By breaking down decision-making strategies into the number of steps required to process a given amount of information, Payne et al. (1988, 1993) showed that simpler strategies (i.e., those that require fewer programming processes) can sometimes produce levels of precision similar to those produced by more complex strategies.

About the design strategies of the geographic profile and following the line of work of Snook, Zito, Bennell, and Taylor (2004), in which they classify the algorithms for the geographic profile into two categories based on their global strategy – spatial distribution strategies and probability distance strategies.

Spatial distribution strategies use geometric characteristics of the crime distribution to make a single-point prediction. The centrophagic model has an analogy in physics, where crime sites are treated as point masses in a system, and the 'centroid' is determined by finding the centre of mass of the system, within the common strategies of spatial distribution we find: centroid, centre of circle, median, geometric mean, harmonic mean and the centre of the minimum distance.

Second, the probability distance strategies develop the development of a methodology to locate the anchor point of the offender in relation to the location of the crimes committed, defining its area of action as the area that contains the residence of the offender.

Software tools that are based on probability distance strategies are based on the use of distance decay functions to calculate a density map. This function shows that most offenders commit their crimes at locations a relatively short distance from their residences: the farther away from home, the fewer crimes are committed. However, only a few crimes are committed in the area immediately around the offender's residence (Snook et al., 2005). This zone with few offenses is called the buffer zone (van der Kemp & van Koppen, 2007). Newton and Swoope (1987) proposed this characteristic as the 'coal-sack effect', whereby the offender, either intentionally or otherwise, avoids committing an offense in particular areas surrounding his or her residence. An explanation of the occurrence of the distance-decay function is given in the rational choice theory (Cornish & Clarke, 1986) and closely resembles the least-effort principle. The distance-decay function is well established as an aggregate description of travel behaviour of offenders, although the shape varies depending on the type of crime or type of offender, is implemented in some software tools for the offender's geographic profile, the best known being Dagnet (Canter, 2003), Rigel™ Criminal Geographic Targeting (K. D. Rossmo, 2000), Predator® (Godwin, 2003) and the CrimeStat® IV journey-to-crime routine (Levine, 2002).

Geographic profiling benefits from increasingly sophisticated software available to its users when using probability distance strategies, but geographic profiling software packages that specifically implement Newton–Swoope buffer analysis are non-existent, except for the program called ATAC Version 2014 9.1 (developed by Bair Analytics [2010], <http://www.bairanalytics.com/> without Access 2020).

To achieve the analysis method, the mathematical model (Equations 1 and 2) was implemented using Python Scripts programming language for a QGIS Environment Development Team (2020) (QGIS Geographic Information System, Open Source Geospatial Foundation Project, <http://qgis.osgeo.org>, accessed 05 May 2020).

When analysing that the definitions of the spatial and probability distribution strategies did not conform to the functions that placed the anchor point in a given area and did not use decay functions for their elaboration, it was decided to classify these in the present text: residual functions, such as a scatter distribution strategy, that uses geometric characteristics of the crime distribution to predict a given area. Within the common dispersion distribution strategies, we find framed: Newton–Swoope geoforensic, Venn diagram, ellipse standard deviation, arithmetic centroid prioritisation, minimum bounding rectangle and the great circle method, also known as the Canter and Larkin environmental range circle theory (1993).

Of all the dispersion distribution strategies, this article tests the predictive capacity of the proposed simple model of Newton and Swoope. The following section details the method carried out for this purpose.

3 | METHODOLOGY

The Newton–Swoope geoforensic method is based on a four-step algorithm:

1. Defines an area of action formed by the minimum bounding rectangle of all crimes.
2. Identify the arithmetic mean of the coordinates of each crime concerning the sequence of the series.

$$\bar{x} = \frac{\sum_{k=1}^n X_k}{n} \quad \bar{y} = \frac{\sum_{k=1}^n Y_k}{n} \quad (1)$$

where \bar{x} represents the mean of all x -coordinates of criminal incidents, \bar{y} represents the mean of all y -coordinates of criminal incidents for each crime scene according to its sequence and k is the total population of crime locations, n .

3. A decreasing radius search is damped around each centroid; the radius is defined by the following equation.

$$R = \frac{\sqrt{A_{xy} / \pi}}{N - 1} \quad (2)$$

where R is the radius, A_{xy} is the distance between the most distant points and N is the total number of incidents. To reduce the size of the search radius after each successive crime, the value of the radius is divided by the total number of crime sites, $N - 1$.

4. The process begins with the first three incidents, resulting in the first circle. Subsequently, it will be the first four incidents and so on. Newton (1988) argues that with each successive murder, an increasingly precise approximation of the location of the 'haven' is obtained. It assumes that the intended location of the 'haven' follows a 'search pattern' that, after the fourth or fifth case, gets closer and closer to the actual 'haven'.

The result is a series of buffer zones in which there is little probability that a crime will be commented on because it is very close to its anchor point (Figure 1). Figure 2 shows a detailed view of the enlarged buffer zone and the final search area (upper profile).

For the evaluation of the measurement of the results, the methodology of the panel of experts of the National Institute of Justice (Rich & Shively, 2004) has been followed. Although the report analyses various evaluation measures of geographic profiles, in this paper, we will focus mainly on the error distance, which is the straight-line distance between the predicted and actual home location, and profile accuracy, which is a binary test of whether the actual home location falls within the top profile region, and is reported as either 'yes' or 'no'.

In the first assumption, Newton and Swoope proposed that after the fifth incident, the estimated 'haven' would approximate the actual 'haven'. To test this assumption, the error distances between the points calculated by the spatial mean of the first six series, and the 'haven' was calculated.

To compare different series with each other, the distances must be standardised: in this case, the methodology proposed by the work of Leitner et al. (2007) standardising the distance in metres in percentages. For each series of crimes, the longest distance between the estimated anchor point and the actual one has a value of 100%. All other (shorter) distances within the same series are expressed as percentages of this longest distance.

To analyse the second assumption, search areas were calculated for each series of six or more crimes, starting with the sixth crime. The calculations, such as the one shown in Table 1, were repeated for each of the 125 crime series. The percentages of the standardised search areas were averaged between series 6 and 11 of the 41 murderers in the sample.

3.1 | Data

Given that the existing definition of serial murder is full of controversies (Adjorlolo & Chan, 2014), the clarifications provided by Delisi and Scherer (2006) were taken into account in order not to allow semantic problems to hinder the possible understanding of this topic: criminological. We deconstruct the term and select certain components to fit our research approach.

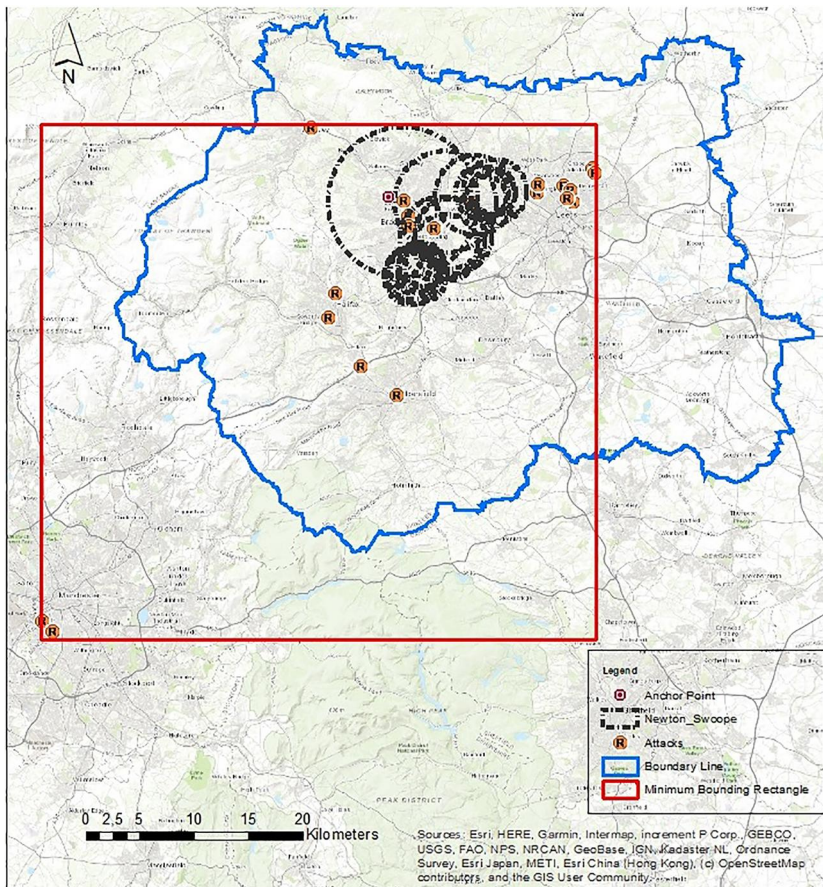


FIGURE 1 Geoforensic analysis method of Peter Sutcliffe

The issue of serial murder has caused much controversy. To date, there is no consensus on the definition of serial murder, mainly due to the different perspectives of academia, on the one hand, and law enforcement agencies, on the other (Bartol & Bartol, 2013; Douglas, Ressler, Burgess, & Hartman, 1986; Edelstein, 2014; Fox & Levin, 2014; Morton & Hilts, 2008). The most common number is a minimum of three victims (Holmes & Holmes, 1998); however, some researchers, such as Jenkins (1994), use four or more as a cut-off point. One of the main debates, for example, is the number of victims that defines serial murder (Yaksic, 2018). However, common to all studies is the understanding that a serial murder is a unique phenomenon since there must be a cool-down period between every two murders.

To be included in our analysis, a criminal must have committed six or more murders, in separate cases, and with a cool-down period between crimes (days, months and years). We also include cases of two or more murders that occurred on the same day, but only if they were not at the same time and in the same place.

Many authors use this time element as part of their exclusion criteria, arguing that a series of serial murders must be composed of such time interruptions. Although a group of experts decided to eliminate the need to include a cool-down period of inactivity in the definition of serial homicide, finding no common ground according to a standard duration of 'cool-down', these lapses between homicides generally span a portion of the time between the conclusion of the earlier murder of the offender and the beginning of the subsequent murder.

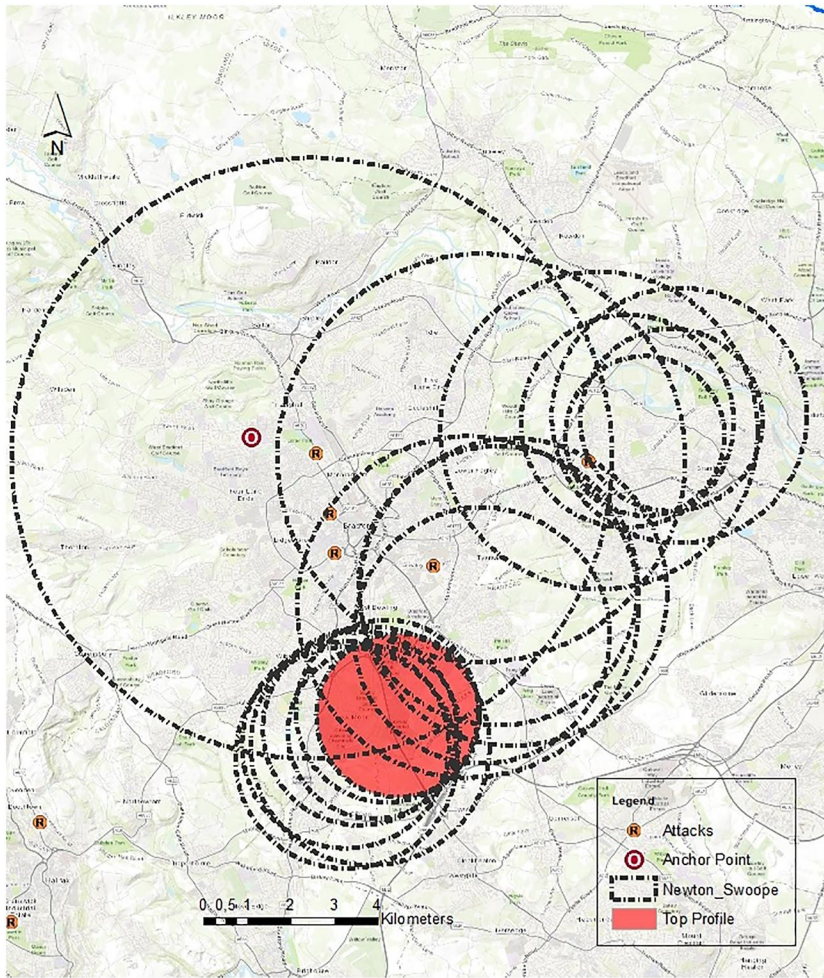


FIGURE 2 Newton–Swoope buffer of Peter Sutcliffe. Enlarged buffer zone. The red area represents the top profile

For an in-depth understanding of the Newton–Swoope model, it has been decided to select from the set of data used in this study, the case of Peter Sutcliffe as a research design strategy, in order to achieve a greater approximation of the model's operation.

3.1.1 | Case study (research design strategy)

Between the years 1975 and 1980, Peter Sutcliffe (the ripper of Yorkshire) left a trail of terror over the north of England. After nine attacks in the surroundings of the cities of Leeds and Bradford, he left West Yorkshire and crossed the Pennines until he arrived in Manchester. Afterwards, he moved from city to city without ever committing a crime twice in a row in the same place. It appears he switched to different areas and directions to commit the murders, but he also murdered three victims near his residence in Garden Lane, Heaton, Bradford. When Peter Sutcliffe was arrested in Sheffield, England, the nature of quantitative criminology changed forever. Sutcliffe's arrest meant a personal victory for Stuart Kind, the forensic biologist whose innovative application of mathematical principles successfully predicted that the Yorkshire ripper lived between the cities of Shettley and Bingley. However, most

TABLE 1 Average standardised search area for increasing counts of attacks locations

Serial killers	Number of killers series analysed	Average standardised distance between predicted and actual 'haven' (%)	Standard deviation	Average standardised search area (%)	Standard deviation	Profile accuracy	
						No	Yes
Serial 6	41	91.1	19.0	78.7	32.9	38	3
Serial 7	28	86.1	24.4	63.2	28.5	26	1
Serial 8	21	88.6	22.6	56.2	30.2	21	1
Serial 9	14	77.6	19.8	52.1	32.1	14	0
Serial 10	11	76.4	16.3	66.0	33.4	11	0
Serial 11	10	75.8	21.3	69.5	24.0	09	1

importantly, that success in early 1981 marked the beginning of 3 decades of research, developing increasingly powerful methods to analyse crime patterns with mathematical models (Godwin & Canter, 1997).

3.1.2 | Case study

Inclusion criteria were based on access to multiple sources of verifiable data, so that cross-checks and factual validity could be established. An original list of 94 international serial killers was first compiled from the Consolidated Serial Homicide Offender Database, Harvard Dataverse (Aamodt et al., 2020), and from this, and applying the selection criteria, a sample of 41 murderers and 125 series was obtained. Obviously, it is very difficult to establish an actual number of victims, so the estimates were calculated based on the cross-validation of the sources. The average number of victims ranged from 6 to 11 victims. According to the travel behaviour developed by Canter and Larkin (1993), 77.60% of murderers are marauders and 22.4% are commuters (Table 2). Marauders commit their crimes with their home base as a nexus of criminal activity, from which the offenses spread into the surrounding area. Commuters travel from their homes to separate areas to commit crimes.

In relation to the series, we can describe it as a 'mixed' case, since some locations of the murders of the same series are distributed outside the area of the 'Circle Hypothesis' procedure detailed by Canter and Larkin (1993). For the purposes of this research, their approach was mathematically automated by calculating the ratio of the maximum distance between crime scenes and offender residence to the maximum distance between the two farthest crime scenes.

$$\text{Offender model} = \frac{d_{cr}}{d_{cc}} \quad (3)$$

where d_{cr} is the distance from the farthest crime to the offender's residence and d_{cc} is the maximum distance between crimes. The offender was categorised as a marauder if the ratio was less than 1.0, or a commuter if the ratio was equal or greater than 1.0 (Kent, 2009).

4 | RESULTS

From the standardised results obtained in Table 3, which corresponds to the Peter Sutcliffe series, it is observed that the longest distance of 9867 m is standardised as 100%, the second longest distance of 9680 m as 98% and so on. The process is similar in the case of the search area in each series. The search areas vary from a minimum of 10.60 km² to a maximum of 48.56 km².

TABLE 2 Series analysed marauder commuter

Series	Number of killers series analysed	Marauder	Commuter
Serial 6	41	28	13
Serial 7	28	20	8
Serial 8	21	17	4
Serial 9	14	13	1
Serial 10	11	10	1
Serial 11	10	9	1

Calculations, such as the example included in Table 3, were performed for 125 series of crimes. The resulting percentages were standardised for each series, starting with the first 6 and ending with the first 11 attacks. Eight series with 12 or more murders were not included in Table 3, because their averages would have been calculated from very small sample sizes (<10) and therefore would have been less representative.

The results in Table 1 show a general trend of a decrease in the average of the average standardised distances between the estimated and the real haven. In general, the distances decrease from 91.1% for series 6 to 75.8% for series 11. These results confirm, in principle, the assumption that the estimated 'haven' is closer to each successive crime after the fifth crime from the series.

In the second assumption raised by Newton, the search area becomes smaller with each successive crime after the fifth series.

The results in Table 1 show a decreasing trend of the search areas from 78.75 for series 6 to 52.1% for series 9, producing an upward trend from series 9 to series 11 with an increase of 69%. However, these results do not, in principle, confirm the assumption that the search area gets smaller with each successive burglary after the fifth case.

The last assumption states that the actual anchor point is within the search area after the fifth crime. In this case, profile accuracy has been used to respond to Newton's approach. The results show that in 95.2% (119 out of 125) of all murder series, the actual 'haven' falls outside any of the planned search areas with six or more cases.

5 | DISCUSSION

The proposed Newton and Swoope's geoforensic process model has not given the expected performance when incorporating a mixed sample about the offender's classification (75.60% marauders and 24.4% are commuters). In relation to the series, we can describe them as 'mixed' series, since some locations of the murders of the same series are distributed outside the area of the 'Circle Hypothesis'. However, there is currently no way to classify in advance whether a killer can have marauders or commuter's behaviour, it is likely that in the murderers' criminal career, they have passed through both states. This is why it seems tighter when testing geographic profiling models to use mixed samples.

Besides, a characteristic of the data sets is that when adjusting the sample to the research criteria (more than five series), the samples were not very large (41 killers and 125 series), so it can reduce the general effectiveness and the investigative confidence of the analysis, suggesting some caution regarding the generalisability of these results.

As Newton and Swoope (1987) pointed out, the ability to develop a meaningful geographic estimate of the haven of a serial offender depends on the mobility characteristic of the offender. Because most serial crimes are not discovered (or lack the necessary association for a series of crimes) through investigation, it can be difficult to come up with a collection of linked crime sites. Consequently, too small a sample of criminal characteristics can reduce the overall effectiveness and investigative reliability of the analysis (Kent, 2003).

TABLE 3 Non-standardised and standardised distances calculated between the estimated and the actual 'haven' for increasing counts of attack locations for one selected by Peter Sutcliffe

Serial killer	Straight-line distances between the estimate and actual (metres)	Standardised distance between predicted and actual 'haven' (%)	Size of search area (km ²)	Standardised size search area (%)
Serial 6	9.867	100	27.14	56
Serial 7	8.665	88	18.84	39
Serial 8	9.680	98	13.84	29
Serial 9	9.061	92	10.60	22
Serial 10	6.342	64	48.56	100
Serial 11	7.014	71	39.33	81

Concerning the time component, it is an issue that may cause some controversy. Researchers mostly state that 'they range from days to weeks or months' (Bartol, 1994; Geberth, 2006; Osborn & Salfati, 2015), others argue (Barnett et al., 1989) that they found, in relation to the intervals between crimes, classifying two types of offenders: the 'frequent' had a daily probability between 1 and 320 of committing a crime, while the 'occasional' had a 1 in 913 daily chance of committing a crime. Additionally, other studies have shown that frequent or high-rate offenders tend to experience relatively short intervals of time before relapsing (Piquero et al., 2007).

Also, when comparing the results with the previous studies described (Leitner et al., 2007), one must take into account the criminal typologies that can be found from those that focus on the nature of the crimes and those that pay attention to the offender behavioural properties for a single crime type (Beauregard et al., 2007; Warren et al., 1999).

However, there are several problems with the process. More importantly, the search radius assumes an isotropic surface, so any location within the radius has an equal chance of being the residence of the offender. While Newton acknowledges the significant impact that the prevailing landscape has on the commission of a criminal act, there is no attempt to fit an anisotropic surface when estimating residence. Similarly, it occurs in current probabilistic profiling models that assume an isotropic surface, where obstacles are uniform in all directions. As a consequence, these models do not adapt to the inherent variations exhibited by a particular transport network, such as route, direction, speed, landscape characteristics, urban development, limits, and so on. Very few of them include geographic actors (functional distances) in their analysis of geographic profiling as a variable that influences the offender's spatial behaviour (Salafranca et al., 2020).

With the evaluation of the geographical profile, this test has shown that the best performance has been in the successive proximity of the estimated point with the domicile in each series from the fifth incident. The expected result can be very useful for analysing geographic profiling models in police organisations. The second proposed assumption has not had the expected answer, taking into account that the analysed algorithm makes use of the arithmetic mean, being quite sensitive to certain outliers, distorting the search radius values in some series, resulting in areas of search that get bigger and bigger after each iteration.

One of the reasons the following assumption does not hold is because the algorithm uses descriptive statistics that are quite sensitive and susceptible to spatial outliers. Bearing in mind that the killer can act at distances both very close and far from his activity space can distort the search radius values, resulting in search areas that become larger and larger after each iteration (series 9–11). In this sense, the search areas of several square kilometres are probably too large to be effective in the process of locating the offender's domicile. As such, the search parameter, which in itself can be considered a form of decreased distance, is not empirically defined (Kent, 2003).

The third assumption analysed has been the one with the least success, only in 6 series of 125 the real 'haven' is located within the final search area (upper profile) after the 5th series. In this sense, we cannot consider the superior profile as a good indicator for the search for the 'haven' of a criminal.

Finally, in the future, new adjustments to the equation may be considered to determine if the centre minimum distance offers better results than in the initial model and the criminal typologies that can be analysed should be taken into account, from those that focus on the nature of crimes and those that pay attention to the behaviour properties of the offender for a single type of crime, is interesting to make a classification and an adjustment of the model in relation to the crime typologies.

ORCID

Daniel Salafrañca Barreda  <https://orcid.org/0000-0003-3442-2001>

REFERENCES

- Aamodt, M., Fox, J. A., Hickey, E., Hinch, R., Labuschagne, G., Levin, J., ... Yaksic, E. (2020). *Consolidated serial homicide offender database*. Retrieved from https://dataverse.harvard.edu/dataverse/serial_homicide
- Adjorlolo, S., & Chan, H. C. (2014). The controversy of defining serial murder: Revisited. *Aggression and Violent Behavior*, 19(5), 486–491. <https://doi.org/10.1016/j.avb.2014.07.003>
- Bair Analytics (2010). *Automated tactical analysis of crime (Version 2014.9 .1)*, Colorado: Bair Analytics Inc. www.bairanalytics.com
- Barnett, A., Blumstein, A., & Farrington, D. (1989). A prospective test of a criminal career model. *Criminology*, 27(2), 373–388. <https://doi.org/10.1111/j.1745-9125.1989.tb01038.x>
- Bartol, C. R. (1994). The psychology of criminal behavior. *Criminal Justice and Behavior*, 21(3), 366–372. <https://doi.org/10.1177/0093854894021003006>
- Bartol, C. R., & Bartol, A. M. (2013). *Criminal & behavioral profiling*. Thousand Oaks, CA: Sage.
- Beauregard, E., Rossmo, D. K., & Proulx, J. (2007). A descriptive model of the hunting process of serial sex offenders: A rational choice perspective. *Journal of Family Violence*, 22(6), 449–463. <https://doi.org/10.1007/s10896-007-9101-3>
- Canter, D. (2003). *Mapping Murder: The secrets of geographic profiling*. Great Britain: Virgin Books.
- Canter, D., & Larkin, P. (1993). The environmental range of serial rapists. *Journal of Environmental Psychology*, 13(1), 63–69. [https://doi.org/10.1016/S0272-4944\(05\)80215-4](https://doi.org/10.1016/S0272-4944(05)80215-4)
- Cohen, E., & Felson, M. (1979). Social Change and crime rate trends: A routine activity approach. *American Sociological Review*, 44. <https://doi.org/10.2307/2094589>
- Cornish, D. B., & Clarke, R. V. G. (1986). *The reasoning criminal: Rational choice perspectives on offending*. New York, NY: Springer-Verlag.
- Delisi, M., & Scherer, A. M. (2006). Multiple homicide offenders: Offense characteristics, social correlates, and criminal careers. *Criminal Justice and Behavior*, 33(3), 367–391. <https://doi.org/10.1177/0093854806286193>
- Douglas, J. E., Ressler, R. K., Burgess, A. W., & Hartman, C. R. (1986). Criminal profiling from crime scene analysis. *Behavioral Sciences and the Law*, 4(4), 401–421. <https://doi.org/10.1002/bsl.2370040405>
- Edelstein, A. (2014). *Multiple-victims murder*. Tel Aviv: eBookPro.
- Geberth, W. J. (2006). *Practical homicide investigation*. Boca Raton, FL: CRC Press.
- Godwin, M. G. (2003). *Psycho-geographical profiling*. Retrieved from <http://www.drmauricegodwin.com>
- Godwin, M., & Canter, D. (1997). Encounter and death: The spatial behavior of US serial killers. *Policing*, 20(1), 24–38. <https://doi.org/10.1108/13639519710161999>
- Holmes, R. M., & Holmes, S. T. (1998). *California: Serial murder* (2nd ed.). California: Sage Publications, Inc.
- Jenkins, P. (1994). *Using murder: The social construction of serial homicide*. New York, NY: A. de Gruyter.
- Kent, J. (2009). Essays on the integration of anisotropic landscapes within contemporary geographic profiling models (Issue December) (LSU doctoral dissertations). Retrieved from https://digitalcommons.lsu.edu/gradschool_dissertations/2903
- Kent, J. (2003). Using functional distance measures when calibrating journey-to-crime distance decay algorithms (MSc Thesis). Louisiana State University. Retrieved from https://digitalcommons.lsu.edu/gradschool_theses/4130
- Kent, J., Leitner, M., & Curtis, A. (2006). Evaluating the usefulness of functional distance measures when calibrating journey-to-crime distance decay functions. *Computers, Environment and Urban Systems*, 30, 181–200. <https://doi.org/10.1016/j.compenvurbsys.2004.10.002>
- Leitner, M., Kent, J., Oldfield, I., & Swoope, E. (2007). Geoforensic analysis revisited—the application of Newton's geographic profiling method to serial burglaries in London, UK. *Police Practice and Research*, 8(4), 359–370. <https://doi.org/10.1080/15614260701615060>
- Fox, J. A., & Levin, J. (2014). *Extreme killing: Understanding mass and serial murder*. Los Angeles, CA: Sage.
- Levine, N. (2002). *CrimeStat: A spatial statistics program for the analysis of crime incident locations (v 2.0)*. Washington, DC: National Institute of Justice.

- Morton, R. J., & Hiltz, M. (2008). *Serial murder: Multi-disciplinary perspective for investigators*. Washington, DC: National Center for the Analysis of Violent Crimes.
- Nagin, D. (2007). Moving choice to center stage in criminological research and theory. *Criminology*, 45, 259–272.
- Newton, M. B. (1988). *Geographical discovery of the residence of an unknown dispersing localized serial murder*. Baton Rouge, LA: Louisiana State University.
- Newton, M. B., & Swoope, E. A. (1987). *Geoforensic analysis of localized serial Murder: The Hillside stranglers located*. Paper presented at the 39th Annual Meeting of the American Academy of Forensic Sciences, San Diego, CA.
- Osborne, J. R., & Salfati, C. G. (2015). Re-conceptualizing “cooling-off periods” in serial homicide. *Homicide Studies*, 19(2), 188–205. <https://doi.org/10.1177/1088767914526716>
- Payne, J. W., Bettman, J. R., & Johnson, E. J. (1988). Adaptive strategy selection in decision making. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 11, 14–27.
- Payne, J. W., Bettman, J. R., & Johnson, E. J. (1993). *The adaptive decision-maker*. Cambridge, MA: Cambridge University Press.
- Piquero, A., Farrington, D., & Blumstein, A. (2007). *Key issues in criminal career research: New analyses of the Cambridge study in delinquent development (Cambridge studies in criminology)*. Cambridge University Press. Retrieved from <https://doi.org/10.1017/CBO9780511499494>
- QGIS Development Team. (2020). *QGIS geographic information system*. Open Source Geospatial Foundation Project. Retrieved from <http://qgis.osgeo.org>
- Rich, T., & Shively, M. (2004). *A methodology for evaluating geographic profiling software: Final report*. Cambridge, MA: Abt Associates Inc.
- Rossmo, D. K. (1997). Place, space, and police investigations: Hunting serial violent criminals. In D.V. Canter & D. Youngs (Eds.), *Principles of geographical offender profiling* (pp. 1–16). Routledge. Retrieved from <https://doi.org/10.4324/9781315246086>
- Rossmo, K. D. (2000). *Geographic profiling*. Boca Raton, FL: CRC Press.
- Salafranca, D., Rodríguez, S., & Mateu, J. (2020). Geographic profiling: Behavior and adaptation to the environment. *International E-Journal of Criminal Science*, 15(2020), 1–27.
- Snook, B., Canter, D., & Bennell, C. (2002). Predicting the home location of serial offenders: A preliminary comparison of the accuracy of human judges with a geographic profiling system. *Behavioral Sciences & the Law*, 20(1–2), 109–118. <https://doi.org/10.1002/bsl.474>
- Snook, B., Taylor, P. J., & Bennell, C. (2004). Geographic profiling: the fast, frugal, and accurate way. *Applied Cognitive Psychology*, 18(1), 105–121. <https://doi.org/10.1002/acp.956>
- Snook, B., Zito, M., Bennell, C., & Taylor, P. J. (2005). On the complexity and accuracy of geographic profiling strategies. *Journal of Quantitative Criminology*, 21(1), 1–25. <https://doi.org/10.1007/s10940-004-1785-4>
- van der Kemp, J., & Y van Koppen, P. (2007). Perfeccionamiento del perfil geográfico. R. Kocsis *Perfiles criminales: perspectivas internacionales en teoría, práctica e investigación*, 347–364). Humana: Totowa, NJ. https://doi.org/10.1007/978-1-60327-146-2_17
- Warren, J., Reboussin, R., Hazelwood, R. R., Gibbs, N. A., Trumbetta, S. L., & Cummings, A. (1999). Crime scene analysis and the escalation of violence in serial rape. *Forensic Science International*, 100(1–2), 37–56. [https://doi.org/10.1016/s0379-0738\(98\)00158-](https://doi.org/10.1016/s0379-0738(98)00158-)
- Yaksic, E. (2018). The folly of counting bodies: Using regression to transgress the state of serial murder classification systems. *Aggression and Violent Behavior*, 43, 26–32. <https://doi.org/10.1016/j.avb.2018.08.007>

How to cite this article: Salafranca Barreda D. The application of Newton and Swoope's geographical profile to serial killers. *J Investig Psychol Offender Profil*. 2021;18:68–78. <https://doi.org/10.1002/jip.1566>

ANEXO F

INDICIO DE CALIDAD DE LA TESIS DOCTORAL

(ARTÍCULO CIENTÍFICO)

El perfil geográfico: comportamiento y adaptación al medio.

Geographic profiling: behavior and adaptation to the environment

Daniel Salafranca Barreda¹, Samuel Rodríguez Ferrández, Jorge Mateu Mahiques

Centro Crimina. Universidad Miguel Hernández de Elche

Resumen

No hay teorías geográficas directas que brinden explicación de la distribución espacial del delito, sino que se ha establecido un vínculo entre la geografía humana y la criminología como resultado del desarrollo del fuerte paralelismo existente. En este contexto no tenemos constancia de la existencia de investigaciones que hayan comprobado la eficacia de la variable de distancia en modelos probabilísticos de perfilado geográfico. Una primera cuestión importante para los algoritmos de perfilado geográfico es determinar la métrica apropiada para medir la distancia, considerando que su comportamiento y adaptación al medio es fundamental para salvar los obstáculos del entorno. En este sentido, el siguiente estudio tiene por objetivo explorar la influencia de los nodos y rutas en el marco de la llamada *journey to crime*, de los delitos realizados por Peter Sutcliffe (*Yorkshire Ripper*) entre los años 1975 y 1980, comparando tres medidas de distancia; directa (Euclidiana), indirecta (Manhattan) y distancias funcionales, concretamente métricas calculadas con el algoritmo Dijkstra's, con el fin de evaluar si la distancia seleccionada varía al aplicar una función exponencial negativa en un perfil geográfico.

Palabras clave: *criminología ambiental; viaje al crimen; perfil geográfico; algoritmo Dijkstra's; distancia de decaimiento.*

Abstract

¹ Correspondencia: d.salafranca@crimina.es

There are no direct geographical theories that provide an explanation of the spatial distribution of crime, but rather a link between human geography and criminology as a result of the development of the strong existing parallelism. In this context, we do not have evidence of the existence of investigations that have verified the effectiveness of the distance variable in probabilistic models of geographic profiling. A first important issue for all geographic profile methods is to determine the appropriate metric to measure the distance, their behavior and adaptation to the environment are fundamental to overcome environmental obstacles. In this sense, the following study aims to explore the influence of the nodes and routes in the framework of the so-called journey to crime, of the crimes committed by Peter Sutcliffe (Yorkshire Ripper) between 1975 and 1980, comparing three measures of distance; direct (Euclidean), indirect (Manhattan) and functional distances, specifically metrics calculated with the Dijkstra's algorithm, in order to evaluate whether the selected distance varies when applying a negative exponential function in a geographic profile.

Keywords: *environmental criminology; journey to crime; geographic profiling; Dijkstra's algorithm; distance decay.*

1. Introducción.

Los esfuerzos combinados de los Brantingham, Newton, Canter, Rossmo, Levine e innumerables otros han sido fundamentales para el desarrollo de técnicas de perfil geográfico, una herramienta de análisis espacial y de apoyo a la decisión, que consta de varias metodologías de investigación y análisis, que utilizan los criminólogos o las organizaciones policiales para predecir el área más probable de residencia del delincuente mediante el análisis de la ubicación de una serie de delitos vinculados (Rossmo, 2000).

El extenso cuerpo de trabajo establecido por estos investigadores continúa expandiendo e inspirando a otros a desarrollar nuevas técnicas y estrategias que en última instancia mejorarán su aplicación. En este sentido, el presente estudio exploratorio trata de profundizar cómo medir el componente espacial del perfil geográfico, utilizando métricas espaciales como el algoritmo Dijkstra's, escasamente exploradas en los modelos probabilísticos de perfilado geográfico.

En el desarrollo de las investigaciones sobre las conductas de movilidad ha sido comúnmente asumido el cálculo de la distancia en línea recta o euclidiana entre el lugar del domicilio del delincuente y la escena del delito, como indicador de la distancia

recorrida. Esto significa que los modelos de perfilado probabilísticos actuales asumen una superficie isotrópica, donde los obstáculos son uniformes en todas las direcciones. Como consecuencia, estos modelos no se adaptan a las variaciones inherentes exhibidas por una red de transporte particular, como la ruta, dirección, velocidad, características del paisaje, desarrollo urbanístico, límites, etc. Son muy pocos los que incluyen en sus análisis de perfilado geográfico a los actores geográficos (distancias funcionales) como una variable que influya en el comportamiento espacial del delincuente. En este contexto no tenemos constancia en España de la existencia de estudios exploratorios que hayan comprobado la eficacia del algoritmo Dijkstra's en estrategias de distancia de probabilidad.

A raíz de estos planteamientos surge la necesidad de explorar un área asimétrica del entorno urbano y comprobar si las características del paisaje pueden aumentar significativamente la exactitud del perfil geográfico.

1.1. Revisión de la literatura.

El perfil geográfico está arraigado en varias teorías sociológicas y particularmente, en la criminología ambiental. Desde los años veinte, la escuela de Chicago ha desarrollado varios métodos para analizar la distribución del delito. Estas técnicas intentaron explicar las variaciones espaciales de los delitos por la organización específica de las ciudades y sus procesos ecológicos y urbanos relacionados (Capone & Woodrow W. Nichols, 1976). Consideraron factores como la tipología delictiva, el *modus operandi* en un hecho delictivo y, finalmente, cómo influye la distancia media en la comisión de un delito. En la década de 1980, los criminólogos ambientales destacaron la importancia de la dimensión en el análisis de la delincuencia, y ello alentó al análisis espacial a herramientas para reducir el área de búsqueda del delincuente (Brantingham, P. J., & Brantingham, 1981). Teorías como la de las actividades cotidianas (E. Cohen & Felson, 1979), elección racional (Cornish, D. B., & Clarke, 1986) y la teoría del patrón delictivo (Brantingham & Brantingham, 1981, 1984, 1993), se utilizaron para describir las características espaciales del comportamiento delictivo que se supone que está directamente influenciado por la configuración de su ambiente.

Estas tres teorías proporcionan las bases principales y se han ido desarrollando e incluso han confluído en una única denominación común de teorías de la oportunidad. Cada enfoque aporta una perspectiva única y diferente en un intento de completar los espacios en blanco que otra teoría ha dejado sin respuesta.

El conocimiento de las dinámicas en la forma que aparecen los eventos delictivos en un territorio es concluyente y tiene diferentes formas de aproximarse al mismo; desde

la utilización de la sociología, la antropología, la estadística, el derecho penal, las ciencias policiales y la criminología, entre otras disciplinas que intentan, desde sus campos de competencias, comprender los factores que influyen en el comportamiento delictivo (Norza et al., 2018).

En este contexto las teorías geográficas se utilizan para describir los patrones de actividad de los ciudadanos. Dentro de este marco surge, en primer lugar, la geografía del comportamiento (*Behavioral Geography*) que ha marcado a la geografía norteamericana desde los años 60. Esta geografía, inspirada en el *behaviourismo*, pretende explicar los comportamientos espaciales de los individuos por la percepción y la memorización visual que tienen de su entorno.

La teoría geométrica del crimen investiga el comportamiento espacial del delincuente. Un elemento implícito en este enfoque es la rutina individual que conforma la vida cotidiana, concepto clave para el perfilado geográfico. Las actividades cotidianas tienen lugar entre los nodos de actividad (hogar, lugar de trabajo, área de ocio) y las rutas entre estos nodos. Al moverse entre los nodos, un individuo da forma a un espacio llamado espacio de actividad. Esto representa el área en la que el delincuente generalmente planifica sus actividades no delictivas. El delincuente construye su espacio de oportunidad para cometer delitos como un subconjunto de su espacio de actividad. Este espacio de oportunidad está formado por la distribución no uniforme de los objetivos.

1.2. *Journey to crime.*

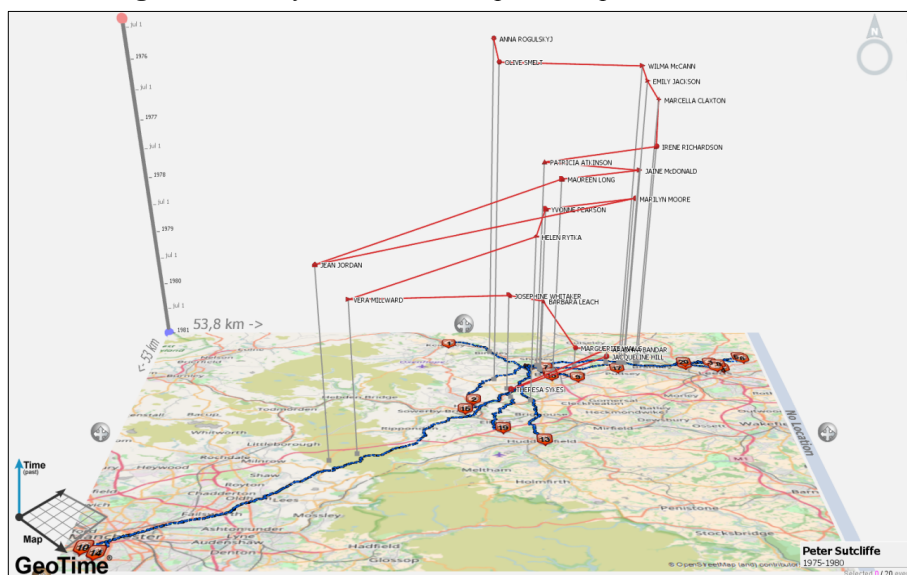
En relación con esas teorías, la mayoría de las metodologías de perfiles geográficos se basan en los principales hallazgos de los estudios de viaje al crimen.

Journey to crime o trayecto al lugar del delito, es un término acuñado por primera vez por P.D. Phillips (1980) y se configura como un área de investigación criminológica que se interesa por las distancias que los delincuentes recorren para cometer delitos, específicamente la distancia desde su domicilio hasta la escena del crimen (Figura 1).

El enfoque de viaje al crimen es un precursor de las técnicas de perfiles geográficos y se ha utilizado durante años para ubicar el origen probable de un delincuente en serie basado en las propiedades asociadas con la distribución de incidentes delictivos (Levine, 2006).

Mientras que la idea de los viajes de los criminales a la delincuencia es relativamente simple, las implicaciones de dónde y por qué los criminales viajan a lugares específicos para cometer un delito afecta a la mayoría de las teorías criminológicas (Rengert, Piquero, & Jones, 2006). Como resultado, la criminología está experimentando el surgimiento de un nuevo enfoque que intenta vincular el lugar de residencia del delincuente con la escena del delito.

Figura1. Journey to crime. Área espacio/temporal de P. Sutcliffe



Fuente: Elaboración propia.

En el análisis del *Journey to crime*, se deben tener en cuenta los siguientes componentes; la motivación del delincuente, el origen, el destino, la ubicación del delito, la ruta que toma, el momento temporal, la duración, la distancia, la dirección, el modo de desplazarse y si lo hace solo o en compañía de otras personas (Bernasco, 2014). Sin embargo, y de forma muy acertada Rengert (2004) encontró, en su revisión bibliográfica que la mayoría de los estudios del trayecto a los delitos, sólo miden la distancia al delito, ignorando el origen y los componentes direccionales de un viaje. Esta observación, tal y como apuntan Andresen, Frank, & Felson (2014), es debido principalmente a la dificultad de obtener información más completa que la incluida en los registros policiales

El análisis de la distancia en relación al *Journey to crime* fue aplicado en los años treinta por White (1932), quien señaló que los delincuentes por delitos contra la propiedad generalmente se desplazaban más lejos que los delincuentes que cometieron delitos contra

las personas. Turner (1969), analizó el comportamiento de la delincuencia por medio de una función de desplazamiento a distancia que muestra cómo se acentúan las agresiones que tienden a estar cerca de la residencia del delincuente. Además, se dio cuenta de que la frecuencia de los delitos cometidos disminuyó a medida que la distancia de la residencia aumentaba.

1.3. *Decaimiento con la distancia.*

El postulado de la disminución de la frecuencia de los hechos delictivos en proporción directa al incremento de la distancia respecto al domicilio del agresor está estrechamente ligado al principio superior de cercanía y/o a la ley del menor esfuerzo. Este postulado indica que, bajo la condición de una igual distribución de las posibilidades potenciales (en las que desempeñan un papel determinados parámetros como la atracción del objetivo, el uso de recursos y medios o la necesidad de seguridad), el agresor elegirá las variantes que, desde su punto de vista, le exijan una mínima modificación ambiental.

Esta expresión encuentra sus raíces en la familia de modelos gravitacionales basada en la ley fundamental de atracción de Isaac Newton (Kent, Leitner, & Curtis, 2006). Según estos autores, el término decaimiento con la distancia se utilizó originalmente para describir el hecho de que la atracción entre dos cuerpos disminuye a medida que aumenta la distancia entre ellos.

El hallazgo recurrente de que la mayoría de los viajes delictivos son cortos frecuentemente se conoce como una función de decaimiento con la distancia. La frecuencia de los viajes delictivos tiende a disminuir a medida que aumenta la distancia desde el punto de origen del delincuente. Esta relación inversa entre la distancia y la frecuencia de viaje se argumenta como evidencia de la preferencia racional de los analistas (Cornish & Clarke, 1986) para minimizar el esfuerzo percibido y el tiempo requerido para localizar objetivos de crimen adecuados.

2. Método

Para la elaboración del siguiente estudio exploratorio se ha seguido la línea de trabajo de Snook, Taylor & Bennell (2004), en la que clasifican los algoritmos para el perfil geográfico en dos categorías básicas: estrategias de distribución espacial y estrategias de distancia de probabilidad, siendo esta última en la que nos centraremos fundamentalmente.

Las estrategias de distancia de probabilidad desarrollan una metodología para situar el punto de anclaje o domicilio del delincuente en relación con la ubicación de los delitos realizados. Definiendo su área de actuación en la zona que contiene el domicilio del delincuente, estos modelos se basan en investigación de *Journey to crime* y asume que la probabilidad de cometer un delito disminuye con la distancia desde el domicilio.

Hay tres programas informáticos de perfiles geográficos comúnmente utilizados que implementan esos modelos: *Rigel* (Rossmo, 2000), *DragNet* (Canter et al., 2012) y *CrimeStat IV* (Levine & Associates, 2013). *Rigel* se basa en el algoritmo (CGT por sus siglas en inglés de *Criminal Geographic Targeting*), *DragNet* usa una función exponencial negativa, que asume que la probabilidad de localizar el hogar de un delincuente en serie disminuye exponencialmente al aumentar la distancia desde su ubicación del crimen; y *CrimeStat* permite al usuario seleccionar entre cinco funciones de disminución de distancia: lineal, exponencial negativa, normal, lognormal y exponencial negativa truncada. Cada programa utiliza algoritmos matemáticos y parámetros que se basan en su propia investigación empírica en el comportamiento de viaje de los delincuentes, con base en la distribución de las distancias de viaje, y han determinado qué forma de función de disminución de distancia es la más adecuada. En relación con la métrica utilizada para calcular la distancia en los algoritmos utilizados, *Rigel* utiliza la distancia Manhattan, *DragNet* utiliza la distancia euclidiana y *CrimeStat* permite al investigador utilizar la distancia Manhattan o la euclidiana.

Todos los enfoques del perfil geográfico que utilizan una estrategia de distancia de probabilidad, con un método de decaimiento con la distancia, asignan pesos a la escena del crimen en función de la distancia al centroide de cada celda, cuya probabilidad se calcula bajo el supuesto de que los delincuentes cometen delitos en las cercanías de su lugar de residencia. Los lugares de crímenes que están cerca entre sí reciben más peso que los lugares más lejanos.

La predicción de la residencia de un delincuente dentro de este espacio se consigue aplicando, alrededor de cada lugar del delito, una función matemática (Ecuación 1) que genera una malla con un tamaño de celda o cuadrícula determinado sobre la distribución espacial de los incidentes delictivos (área de actuación), aplicando a cada celda un peso en relación con la distancia (*network*, euclidiana y Manhattan) de los incidentes delictivos con respecto al centroide de cada celda (Figura 2). Finalmente, los valores de las celdas son calculados mediante el sumatorio de los valores de cada incidente en función del algoritmo aplicado.

El resultado es una superficie en la que los valores más altos en determinadas zonas indican la probabilidad de que un delincuente pueda vivir dentro de esa área, y la

celda con una puntuación de probabilidad más alta determinará el punto de anclaje del delincuente (Figura 3).

Figura 2 Cálculo de distancia en cuadrícula (euclidiana).




Figura 3 Cuadrícula

por celda

con valor de probabilidad

12	12	13	13	14	13	9	11	16	17
12	14	13	18	18	18	27	24	25	22
17	19	34	22	34	40	31	33	29	21
26	32	40	39	58	59	47	42	39	23
32	55	60	73	77	69	58	59	49	28
29	69	82	87	85	84	69	68	51	30
22	66	88	90	87	85	69	64	44	23
26	64	85	91	93	86	64	67	45	24
28	59	71	84	81	78	70	65	41	34
37	38	49	60	66	68	59	55	40	32

Fuente: Elaboración propia.

Las estrategias de distancia de probabilidad difieren entre sí en cuanto a la forma de la función matemática aplicada en torno a cada lugar del delito y los supuestos con respecto a la relación entre el lugar donde residen los delincuentes y donde cometen sus delitos.

Los investigadores han desarrollado varias funciones diferentes para calcular el decaimiento con la distancia (Levine, 2014). Dentro de las funciones matemáticas más

utilizadas, propuestas por Levine, cabe enumerar las siguientes: lineal, exponencial negativa, normal, lognormal y exponencial negativa truncada (Figura 4). se ha optado por utilizar una función de distribución de probabilidad conocida como distribución exponencial negativa, que se caracteriza porque su función de decaimiento viene dada por la expresión siguiente;

$$f(d_{ij}) = A * e^{-B*d_{ij}} \quad (1)$$

$f(d_{ij})$ es la probabilidad que el delincuente resida en un punto determinado;

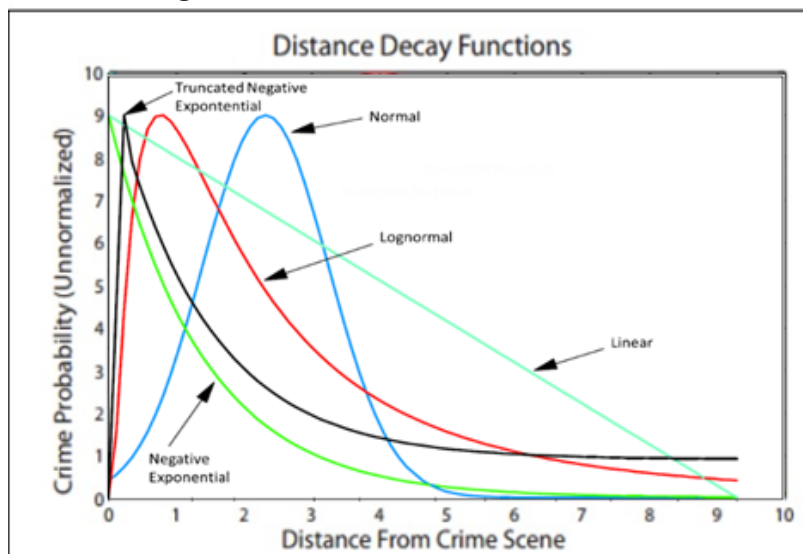
d_{ij} es la distancia entre una localización de referencia y la localización del delito;

e es la base del logaritmo natural;

A es un coeficiente predeterminado con un valor de 1.89 ;

B es un exponente predeterminada con un valor de -0.06 .

Figura4 Funciones de decaimiento de distancia



Fuente: Levine 2007

Para la implementación de la función se ha utilizado el software *ArcGIS* 10.5, incorporando en la tabla de atributos, mediante la función de calculadora de campo, la ecuación (1) función exponencial negativa.

2.1. Distancia.

Los procedimientos de cálculo de distancias pueden ser varios. En primer lugar, se pueden utilizar las ecuaciones más simples, como son la distancia euclidiana y la Manhattan, ambas muy conocidas en criminología. Evidentemente, esto supone una enorme simplificación, ya que los verdaderos recorridos de los criminales para desplazarse de su residencia hasta su objetivo no siguen exactamente este procedimiento. Como es conocido, las personas se desplazan a través de las redes de calles o carreteras que no se tienen en cuenta en el análisis de los perfiles geográficos. No obstante, en la mayoría de los sistemas de perfil geográfico criminal, así como en la gran mayoría de investigaciones de perfil geográfico, el uso de la distancia se basa en la línea recta para calcular predicciones de *Journey to crime* y del domicilio (Kent et al., 2006), lo que significa que las estrategias de distancia de probabilidad actuales asumen una superficie isotrópica, donde la impedancia es uniforme en todas las direcciones.

Una primera cuestión importante para todos los métodos de perfil geográfico es determinar la métrica apropiada para medir la distancia. Un método común en criminología, es utilizar la distancia euclidiana, la distancia más corta entre dos puntos, que responde al concepto tradicional de distancia como hipotenusa de un triángulo rectángulo. Es la más utilizada para resolver problemas geoespaciales:

$$d_2(\mathbf{x}, \mathbf{y}) = \sqrt{(x^{(1)} - y^{(1)})^2 + (x^{(2)} - y^{(2)})^2}. \quad (2)$$

En segundo lugar, disponemos de la distancia de Manhattan, que corresponde, siguiendo con el símil del triángulo rectángulo, a la suma de los catetos.

$$d_1(\mathbf{x}, \mathbf{y}) = |x^{(1)} - y^{(1)}| + |x^{(2)} - y^{(2)}|. \quad (3)$$

En numerosas ocasiones, los problemas geoespaciales han tenido que adaptarse a la ciudad. La literatura geográfica y urbanística han coincidido al definir un modelo de

ciudad norteamericana, en un intento por simular mejor los desplazamientos habituales de los usuarios; especialmente en recorridos a través de medios urbanos donde la línea recta es un tanto irreal, se ha utilizado la distancia Manhattan (Ramírez, 2002). Este modelo se ha elaborado a partir de una serie de características propias del espacio urbano y del sistema de ciudades representativo de Estados Unidos. En este sentido es interesante señalar, que las ciudades británicas carecen del típico formato de patrón de rejilla regular de calles comunes a las ciudades americanas, y que era generalmente difícil identificar la ruta más probable entre dos lugares. Como consecuencia de ello, consideraban que en su estudio era mejor utilizar la distancia euclidiana en comparación con la distancia Manhattan (Wiles & Costello, 2000).

No obstante, las metodologías descritas anteriormente no integran las características geográficas en sus análisis. Para llenar este vacío, se propusieron diferentes soluciones tales como el uso de características de cobertura del suelo para mejorar los modelos de viaje al crimen (Kent et al., 2006) o algún perfil geográfico basado en la red de tráfico ponderado (Qian et al. 2011). El tiempo y el espacio en muchas ocasiones son obstáculos en el movimiento no exento de estas limitaciones. Su comportamiento y adaptación al medio es fundamental para salvar los obstáculos del entorno. El problema surge cuando las personas imaginan el trayecto y lo dibujan en su mapa cognitivo de manera geoméricamente ideal, olvidando el tramado de la red viaria. En este contexto, parece más realista usar los algoritmos de cálculo de costes de recorrido, en los cuales se tienen en cuenta la existencia de carreteras o calles. En este sentido, y planteado el problema de movilidad por las ciudades, se convierte en idea principal el encontrar, a lo largo del amplio conjunto de trayectorias posibles en la red, aquéllas que comporten un menor riesgo/tiempo para el delincuente.

Uno de los algoritmos más difundidos en esta línea de trabajo es el elaborado por Dijkstra. El algoritmo se ajusta a la estrategia conocida como esquema de algoritmo voraz. La idea subyacente en este algoritmo consiste en ir explorando todos los caminos más cortos que parten del vértice origen y que llevan a todos los demás vértices, obteniendo pesos en cada arista; cuando se obtiene el camino más corto desde el vértice origen al resto de vértices que componen el grafo, el algoritmo se detiene. Esta operación de asignar distancias a pares de puntos es precisamente lo que da origen a una revisión en la estrategia de distancia de probabilidad en los modelos de perfilado geográfico y a la necesidad de analizar el patrón de localización de delitos en un entorno urbano/interurbano a través de la red viaria.

2.2. *El estudio de caso.*

Entre los años 1975 y 1980 Peter Sutcliffe (el destripador de Yorkshire) fue dejando un rastro de terror por el norte de Inglaterra. Después de 9 asaltos en los alrededores de las ciudades de Leeds y Bradford, dejó West Yorkshire y cruzó los Pennines hasta llegar a Manchester. Posteriormente, se movió de ciudad en ciudad sin cometer nunca dos crímenes en el mismo lugar. Parece que conmutó a varias áreas y direcciones diferentes para cometer los asesinatos, pero también asesinó a tres víctimas cerca de su residencia, en Garden Lane, Heaton, Bradford.

Cuando Peter Sutcliffe fue arrestado en Sheffield, Inglaterra, la naturaleza de la criminología cuantitativa cambió para siempre. La detención de Sutcliffe marcó una victoria personal para Sturt Kind, el biólogo forense cuya innovadora aplicación de principios matemáticos había predicho con éxito que el destripador de Yorkshire vivía entre las ciudades de Shettley y Bingley. Más importante aún, sin embargo, este éxito marcó, a principios de 1981, el comienzo de tres décadas de investigación desarrollando métodos cada vez más poderosos para analizar patrones criminales con modelos matemáticos (Godwin & Canter, 1997). El enfoque de Kind tomó la práctica de mezclar los cálculos y la prevención del crimen en un nuevo ámbito mediante la aplicación de análisis algorítmicos a los actos delictivos de un delincuente serial (Rossmo, 2000). Desde el innovador cálculo de Kind, la práctica de perfilar geográficamente los crímenes seriales ha producido un cuerpo sustancial de investigación, principalmente enfocada en técnicas para ubicar los puntos de anclaje del delincuente.

2.3. *Datos.*

Se ha optado como factor base a considerar, para realizar un análisis de distribución espacial, los datos de Peter Sutcliffe, que se identifica con una localización geográfica del primer ataque (nodos de origen). La tabla 1 muestra un total de 20 ataques, incluida la fecha, la víctima, la ciudad y las coordenadas geográficas específicas (longitud y latitud) de los sitios de la localización de los crímenes.

Tabla 1. Información de los ataques

REGISTRO	FECHA	VICTIMA	CIUDAD	LATITUD	LONGITUD
1	7/5/1975	ANNA ROGULSKYJ	KEIGHLEY	53.871481	-1.897633
2	8/15/1975	OLIVE SMELT	HALIFAX	53.734182	-1.864272
3	10/30/1975	WILMA McCANN	LEEDS	53.822352	-1.544942
4	1/20/1976	EMILY JACKSON	LEEDS	53.809052	-1.531635
5	5/9/1976	MARCELLA CLAXTON	LEEDS	53.836585	-1.503293
6	2/5/1977	IRENE RICHARDSON	LEEDS	53.833069	-1.499997
7	4/23/1977	PATRICIA ATKINSON	BRADFORD	53.810211	-1.767216
8	6/26/1977	JAIINE McDONALD	LEEDS	53.818458	-1.535151
9	7/10/1977	MAUREEN LONG	BRADFORD	53.787368	-1.726811
10	10/1/1977	JEAN JORDAN	MANCHESTER	53.461321	-2.273241
11	12/14/1977	MARILYN MOORE	LEEDS	53.812352	-1.5396
12	1/21/1978	YVONNE PEARSON	BRADFORD	53.797916	-1.762342
13	1/31/1978	HELEN RYTKA	HUDDERSFIELD	53.649382	-1.779432
14	5/16/1978	VERA MILLWARD	MANCHESTER	53.453019	-2.257498
15	4/4/1979	JOSEPHINE WHITAKER	HALIFAX	53.71339	-1.874463
16	9/2/1979	BARBARA LEACH	BRADFORD	53.789796	-1.76127
17	8/18/1980	MARGUERITE WALLS	FARSLEY	53.8084	-1.672148
18	9/24/1980	APADHYA BANDAR	LEEDS	53.817419	-1.58065
19	11/5/1980	THERESA SYKES	HUDDERSFIELD	53.673159	-1.828876
20	11/17/1980	JACQUELINE HILL	LEEDS	53.823573	-1.579763

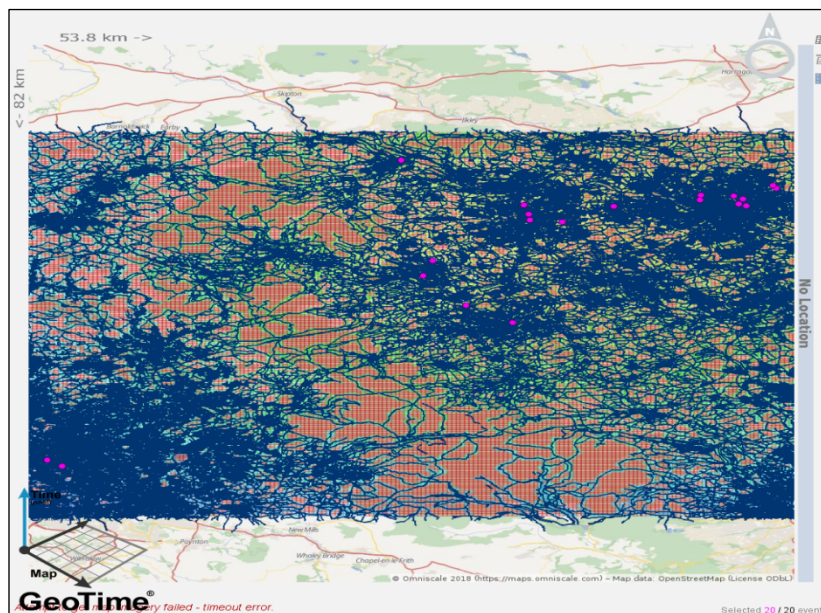
2.4. Delimitación espacial.

El área de actuación en este caso se ha definido como un cuadrado de 10% mayor que el área delimitada por las coordenadas mínimas y máxima XY de las localizaciones del crimen. (parte superior: 53.910181, derecha -1.421570, parte inferior 53.386094, izquierda -2.338565). En segundo lugar, se ha creado mediante la caja de herramientas de *ArcGIS* (ArcToolbox/Data Management Tools/Feature Class / Create Fishnet) una rejilla de referencia 200 por 200 de las celdas superpuestas a la zona de actuación, generando un total de 40.000 celdas.

2.5. Generación de Red.

En tercer lugar, para generar el sistema de elementos interconectados, como bordes (líneas) y cruces de conexión (puntos), que representa las posibles rutas desde una ubicación a otra, ha sido necesario construir la topología de red. Se ha utilizado la extensión de *ArcGIS Network Analyst* que puede realizar los cálculos de coste mínimo necesarios de los *datasets* de red (redes de transporte). Los *dataset* de red están formados por los elementos de la red utilizada. En este caso, se ha partido de una capa vectorial de tipo línea que contiene los ejes de las vías de comunicación, a partir de los *shapefiles* existentes de Gran Bretaña, sub-región Inglaterra: <http://download.geofabrik.de/europe/great-britain.html>.

Mapa de los ejes de vías de comunicación. Gran Bretaña sub-región Inglaterra.



Fuente: Elaboración propia

Las redes de carreteras se han definido como gráficas conectadas, con bordes que representan segmentos de carretera y con nodos que representan intersecciones. Algunas



vías de comunicación, que en la vida real constituyen un solo camino, se dividieron en múltiples. Se han seleccionado un total de 173.464 ejes de vía que delimitan el área de actuación del perfil geográfico (Figura 5).

Para saber cuál es este camino, será necesario calcular la ruta óptima que representará el camino mínimo a seguir desde un punto origen, que se haya dado como entrada, a cada uno de los diferentes destinos determinados en la capa de coste acumulado. El desplazamiento entre dos puntos del espacio implica un coste. Por regla general, cuanto más alejados estén estos dos puntos, más coste en tiempo y energía supondrá desplazarnos. Así pues, podemos definir el coste como la resistencia que presenta el medio por el que nos desplazamos en un punto concreto (Olaya, 2011). La utilización de puntos (rejilla de referencia 200 por 200 de las celdas superpuestas a la zona de actuación, generando un total de 40.000 celdas) para representar la oferta y la demanda mediante el uso de los centroides, puede producir un problema de relación de todos los puntos de la red celular con los de los ejes de las carreteras. Por ello, en cuarto lugar, es necesario resolver el modo cómo estos puntos se van a conectar a la red para que así los cálculos de distancias se puedan realizar. La solución más sencilla de implementar ha sido asignar cada punto de la rejilla al eje de la red existente, justamente aquél que se encuentre a menos distancia en línea recta de él, en la (Figura 6a) se puede observar el desplazamiento del centroide al eje de la vía más cercano (Figura 6b).

Figure 6a

Rejilla simétrica/asimétrica

Figura 6b




Fuente: Elaboración propia

Como se mencionó anteriormente, pocas ciudades tienen una rejilla completamente simétrica, o incluso una que sea aproximadamente similar a una rejilla. Las limitaciones de la topografía física (montañas, océanos, ríos, lagos), así como los

diferentes patrones de desarrollo histórico, hacen que el despliegue sea asimétrico alrededor de la mayoría de las ubicaciones.

Figure 7. Factores de impedancia (algoritmo Dijkstra`s)



Fuente: Elaboración propia

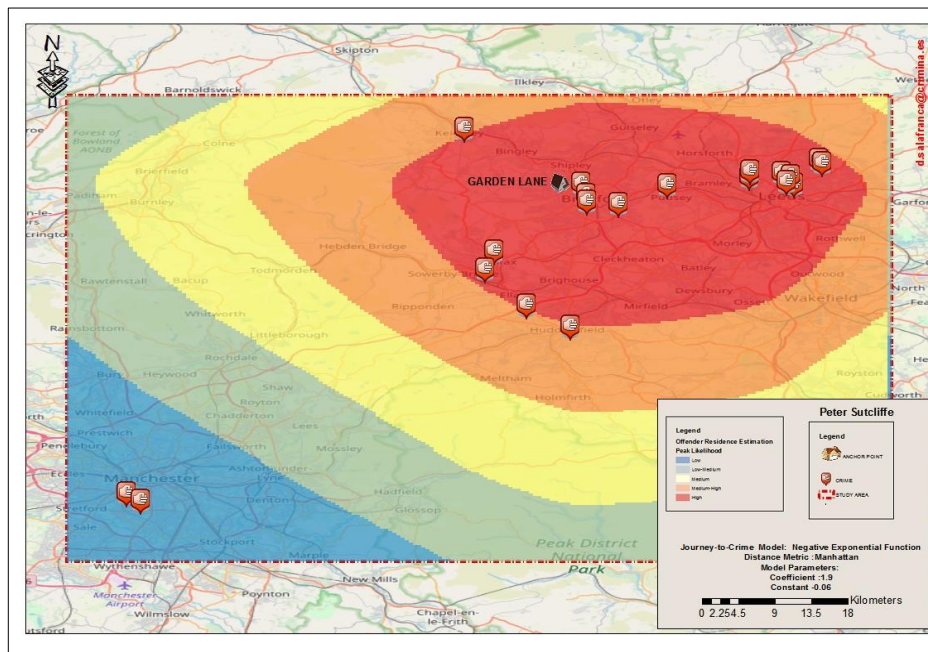
Como consecuencia, estas redes tienen factores inherentes de impedancia que están influenciados por características culturales, físicas y psicológicas (por ejemplo, lagos, ríos, montañas, etc.), que limitan los viajes para ciertas direcciones y velocidades (Barry, 2000; Rossmo 2000). Estos factores influyen significativamente en las consideraciones subjetivas y objetivas de un individuo para viajar y se deben tener en cuenta en el perfilado geográfico. En el estudio se han detectado 9806 celdas (Figura 7) de las 40.000 celdas del área de actuación que no se han modelado por encontrarse con factores inherentes de impedancia (montañas).

Validados y generados todos los campos necesarios se procede a ejecutar el análisis de red, mediante el algoritmo Dijkstra`s. Finalmente, el resultado obtenido corresponde a la distancia entre una localización de referencia (centroide) y la localización del delito, que será calculada en la ecuación (1) función exponencial negativa.

3. Resultados


Al aplicar a cada celda un peso en relación a la distancia Manhattan, euclidiana y *network*, se obtiene una superficie formada por pequeñas unidades de igual tamaño (celdas) con un valor de probabilidad representado por una gama cromática de 5 bandas, siendo la banda de color rojo la que representa la zona de mayor probabilidad de encontrarse el domicilio del agresor (Fig-8,9 y 10).

Figure 8. Mapa Distancia Manhattan



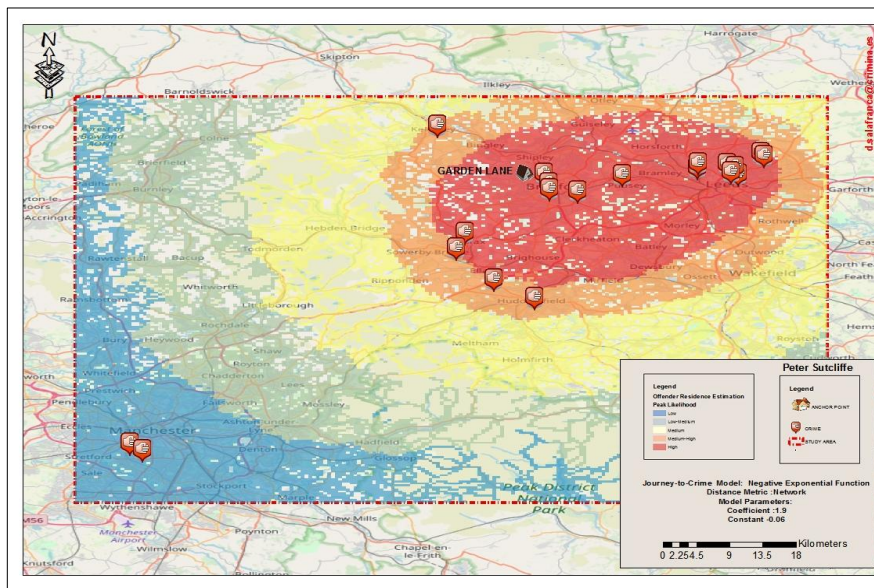
Fuente: Elaboración propia

Figure 9. Mapa Distancia euclidiana



Fuente: Elaboración propia

Figure 10. Mapa Distancia Network



Fuente: Elaboración propia


La distancia media existente entre cada incidente delictivo y cada celda (40.000) fue de 621.666 km. aplicando una distancia euclidiana; 795.881 km. con Manhattan; y 746.195 km. con *network*. (Tabla 2).

Tabla 2. Estadística Descriptiva

	Euclidiana	Manhattan	Network
<i>N</i>	39999	39999	39999
<i>Min</i>	286720	376073	340812
<i>Max</i>	1141863	1608302	1334838
<i>Mean</i>	621666	795881	746195
<i>Std.Error</i>	993	1306	1197
<i>Stand.dev</i>	198673	261363	238023
<i>Median</i>	621099	779062	744319
<i>25 prcentil</i>	444662	574270	532639
<i>75 prcentil</i>	788194	975291	952291

La Figura 11 ilustra las curvas de tres mediciones de distancia diferentes: distancia euclidiana, distancia de Manhattan y distancia *network*, para todos los delitos y todos los centroides. El eje X es la distancia en km. mientras que el eje Y muestra la frecuencia. Las frecuencias se calcularon utilizando una banda de 200 unidades, obteniendo una distribución normal bivariada en las tres medidas.

Figura 11. Histograma de las tres mediciones de distancia



Fuente: Elaboración propia

Como también hicieron Groff & McEwen (2005), quisimos comparar las relaciones estadísticas entre la distancia *network*, la distancia euclidiana y la distancia Manhattan. Para hacer esto, se usaron la correlación y la regresión lineal.

Se aplicó la correlación de *Pearson* para cuantificar la relación entre los métodos de medición, encontrando una correlación lineal cuando se compararon los métodos de euclidiana vs Manhattan, que corresponde a $r = 0,974$ ($p < 0,001$), así como para el método Euclidiana vs Network, con una correlación de $r = 0,929$, y Network vs Manhattan, con $r = 0,899$.

Esta relación se confirma mediante el excelente grado de concordancia entre las variables

Tabla 3. Resultado del coeficiente de correlación de Pearson.

	Distance Euclidiana	Distance Manhattan	Distance Network
Distance Euclidean	1	0,974***	0,929
Distance Manhattan	—	1	0,899
Distance Network	—	—	1

***= $p < 0,001$

La Tabla 4 muestra los resultados de la regresión con la distancia *Network* como variable dependiente, y la distancia euclidiana y Manhattan como variable independiente. La relación entre las variables euclidiana y Manhattan es muy fuerte. El valor R^2 es >0.94 , lo que indica una relación lineal virtualmente perfecta entre las dos distancias. Lo que significa este resultado es que se puede obtener una estimación confiable de los metros de los ejes de vía aplicando los resultados de la regresión entre estas dos variables. Por otro lado, el coeficiente de determinación de las variables Manhattan y *Network* indica que el 80.99% de la variabilidad en la variable dependiente *Network* se tiene en cuenta en este modelo.

Tabla 4. Resultados de la Regresión

	Distance Euclidiana	Distance Manhattan	Distance Network
Distance Euclidiana	1	—	—
R^2	1	0.9489	0.864
Slope	1	1.2815	1.167
Intercept	1	-785.24	11620
Constant	1	32338	75805
Coefficient	1	0.7404	0.7399
Distance Manhattan	—	1	—
R^2	—	1	0.809
Slope	—	1	0.859
Intercept	—	1	53681
Constant	—	1	100721
Coefficient	—	1	0.9423
Distance Network	—	—	1

Para la evaluación de la medición de los resultados, se ha seguido la metodología del panel de expertos del Instituto Nacional de Justicia (Rich & Shively, 2005). Si bien en el informe se analizan diversas medidas de evaluación de perfiles geográficos, en este trabajo nos centraremos fundamentalmente, en el porcentaje de puntaje de éxito (también conocido como el coste de búsqueda) y la distancia de error. El coste de búsqueda determina el área (número de celdas de área constante) para investigar, de acuerdo con los puntajes obtenidos por cada celda antes de encontrar la residencia del delincuente (Canter, Coffey, Huntley, & Missen, 2000). Normalmente se calcula como una relación entre éste área investigada y el área de estudio.

El porcentaje de resultados es una medida de la eficiencia de búsqueda de perfiles geográficos. Se define como la proporción del área de actuación buscada (siguiendo la priorización de perfil geográfico). Cuanto menor sea esta relación, mejor será el enfoque del perfilado. Se calcula añadiendo primero el número de celdas con una puntuación de éxito (valor de verosimilitud) superior a la de la celda que contiene la residencia del delincuente (Garden Lane, Bradford, coordenadas Longitud 53.81376, Latitud - 1.789933) más la mitad del número de vínculos (celdas con la misma puntuación de éxito) y luego dividiendo por el número total de celdas en el área de actuación (40.000 celdas) (Figura 11); en el caso de la distancia Manhattan (color rojo) 395 celdas, en la distancia euclidiana (violeta) 1.751 celdas y en el caso *network* (color amarillo) 1.841 celdas.

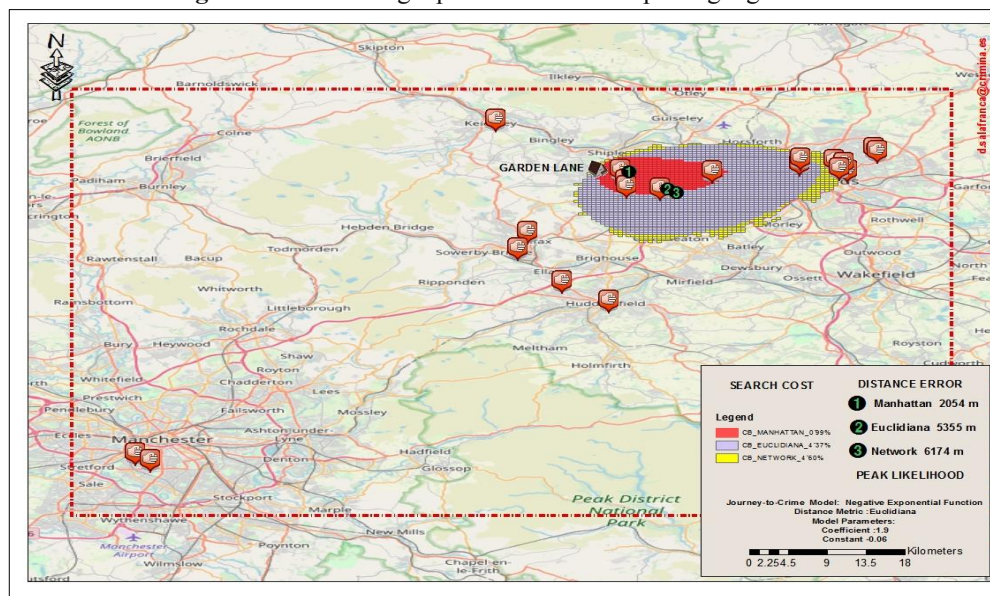
Tabla 5. Resultados de modelos de perfilado.

	Coste de búsqueda (%)	Distancia de error (m)
Euclidean Distance Metric	4'37	5355
Manhattan Distance Metric	0'99	2054
Network Distance Metric	4'60	6174

El indicador de rendimiento más intuitivo es probablemente la distancia entre el mejor resultado y la residencia del agresor, llamada la distancia de error. El procedimiento se basa en la distancia euclidiana entre el centroide de la celda de la cuadrícula con la probabilidad más alta y el domicilio real del delincuente (Figura 11), en relación a las tres medidas aplicadas.

Los resultados de la Tabla 5 respaldan el potencial de las herramientas operativas que utilizan dichos procedimientos para evaluar el perfilado geográfico y contribuyen a nuestra comprensión del comportamiento geográfico del delincuente (Canter, 2004).

Figure 12. Metodología para evaluación de perfil geográfico.



Fuente: Elaboración propia

4. Discusión.

Ciertos diseños utilizados en el perfilado geográfico presuponen que todos los actores son idénticos y que las reglas de comportamiento por las que se rigen son similares. Sin embargo, en el mundo real los actores sociales suelen tener diferentes deseos, creencias, oportunidades y reglas de comportamiento. Hacen falta por tanto nuevos métodos para explorar el comportamiento complejo, no lineal y emergente de los delincuentes seriales.

Un problema importante que surge al diseñar un modelo de perfilado geográfico es decidir qué elementos incluir y cuáles deberían ser excluidos. Cuantos más elementos se excluyan, mayor será la distancia entre las conclusiones obtenidas y la explicación del fenómeno criminológico que se quiera analizar. La teoría de modelar el comportamiento humano discute la conveniencia de tres cualidades: (1) realismo; (2) generalidad; y (3) precisión (Levins, 1966). Desafortunadamente, la mejora en la calidad de un parámetro

generalmente da lugar a en un deterioro en otro. Una mayor precisión, por ejemplo, a menudo significa una pérdida de generalidad.

En este sentido, el algoritmo Dijkstra's, que es un elemento realista en el comportamiento del delincuente, no ha encontrado el mejor rendimiento ni la precisión del perfil geográfico utilizando una estrategia de distancia de probabilidad en relación con las distancias Manhattan y euclidiana.

Aunque estudios previos han utilizado el algoritmo Dijkstra's para medir la distancia en el *Journey to crime* (Kasprzyk, Trotta, Broxham, & Donnay, n.d.), no existen, bajo nuestro conocimiento, investigaciones que hayan validado el procedimiento en modelos probabilísticos de perfilado geográfico, pero sí se han comprobado modelos de distancia directa e indirecta. Por lo tanto, en el estudio exploratorio realizado los resultados obtenidos no son confirmatorios, pero se ajustan a los obtenidos por Groff y McEwen (2005) que la distancia euclidiana y la distancia *Network* tienen una fuerte relación lineal positiva, asumiendo que ambos protocolos pueden ser utilizados en función de las necesidades de la investigación. Otros estudios (Kent, Leitner, & Curtis, 2006), demostraron que, a través de varios tipos de crímenes en serie, la distancia Manhattan ha dado mejor resultados que la euclidiana y que el uso de la distancia *network*, tiene un peor rendimiento en la predicción de puntos de anclaje criminales. En dicha investigación se ha utilizado modelo de perfiles calibrados implantados en las funciones matemáticas (truncada exponencial negativa y exponencial negativa) por consiguiente, la metodología utilizada por Kent (2006) difiere de nuestro modelo, al utilizar modelos calibrados.

El principal resultado del presente estudio fue la alta correlación y concordancia existente entre las distancias medidas (Tabla 3). La mayor correlación de todas las estudiadas fue la que se observó entre la distancia euclidiana y Manhattan ($r = 0,974$). Además, todas las comparaciones fueron altas, con valores de correlación mayores a 0,89.

En relación con la evaluación del perfil geográfico, esta prueba ha demostrado que el mejor rendimiento y más preciso se ha creado cuando las distancias se miden como ruta indirecta en Manhattan con un valor < 1 en el área de máxima puntuación. Cuando las distancias se miden utilizando la distancia *Network*, el tamaño del área de búsqueda se vuelve cuatro veces mayor, en comparación con las distancias medidas con métricas Manhattan.

5. Conclusiones.

Los resultados en esta investigación encuentran innecesario agregar medidas de distancia funcional en los modelos de perfilado geográfico probabilístico. Estos hallazgos respaldan la investigación de Canter (2003), que sugiere que la ruta de viaje real no define el espacio de conciencia del delincuente. Más bien, la conducta del delincuente se basa en el mapa mental del individuo y la percepción selectiva de las características físicas dentro del paisaje real. Como tal, el delincuente percibe el camino entre dos puntos como una línea recta y una gran parte de los estudios sobre desplazamientos criminales también utilizan esta medida de distancia, ya que la distancia entre la residencia del sospechoso y la escena del crimen viene justificada por el hecho de que, a pesar de desconocer la ruta exacta elegida por el autor del crimen, la línea recta nos proporciona en todo caso una estimación razonable de su ámbito de movilidad (Brantingham & Brantingham, 1991; Davis & Dale, 2005; Beauregard et al., 2005; Lundrigan et al., 2009). Dicho esto, la distancia Manhattan o euclidiana se utilizarán en nuestros análisis posteriores por sus altos valores de correlación y la facilidad de ser implementadas en los modelos de perfilado geográfico, ya que también nos posibilitan la realización de comparativas con otras investigaciones (Akerman & Rossmo, 2015; Groff & McEwen, 2007; Rossmo et al., 2004).

Sin embargo, como señalaron Capone y Nichols (1976) hace más de un cuarto de siglo, parece lógico suponer que las diferentes funciones podrían proporcionar los mejores ajustes a distribuciones de distancia para diferentes tipos de delitos, y la investigación futura necesitaría determinar si éste es de hecho, el caso.

Referencias

- Andresen, M., Frank, R., & Felson, M. (2014). *Age and the distance to crime. Criminology & Criminal Justice, 14*(3), 314 - 333.
- Bernasco, W. (2014). Crime Journeys—Patterns of Offender Mobility. *Oxford Handbooks Online in Criminology and Criminal Justice*.
- Brantingham, P. J., & Brantingham, P. L. (1981). *Environmental criminology* (Sage Publi). Beverly Hills.
- Capone, D. L., & Woodrow W. Nichols, J. (1976). Urban Structure and Criminal Mobility. *American Behavioral Scientist, 20*(2), 199–213. <http://doi.org/10.1177/000276427602000203>
- Cohen, L., & Felson, M. (1979). Social Change and Crime Rate Trends: A Routine Activity Approach. *American Sociological Review, 44*. <http://doi.org/10.2307/2094589>
- Cornish, D. B., & Clarke, R. V. G. (1986). *The reasoning criminal: rational choice perspectives on offending*. (©1986. New York : Springer-Verlag, Ed.).
- Godwin, M., & Canter, D. (1997). Encounter and death: The spatial behavior of US serial killers. *Policing An International Journal of Police Strategies Management, 20*(1), 24–38. <http://doi.org/10.1108/13639519710161999>
- Kent, J., Leitner, M., & Curtis, A. (2006). Evaluating the usefulness of functional distance measures when calibrating journey-to-crime distance decay functions. *Computers, Environment and Urban Systems, 30*(2), 181–200. <http://doi.org/10.1016/j.compenvurbsys.2004.10.002>
- Levine, N. (2006). Crime mapping and the crimestat program. *Geographical Analysis, 38*(1), 41–56. <http://doi.org/10.1111/j.0016-7363.2005.00673.x>
- Levine, N. (2014). Chapter 13: Journey-to-Crime Estimation.
- Norza, E., Nancy, C., Espinosa, M. V., Lucía, B., Prieto, A., Rincón, H., & Ospino, M. A. (2018). Criminología ambiental y homicidio en la ciudad de Bogotá (Colombia) 1 *, (January). <http://doi.org/10.7440/res63.2018.05>
- Olaya, V. (2011). Sistemas de Información Geografica.
- Phillips. (1980). *Characteristics and Typology of the Journey to Crime* (United Sta). United States.
- Procedure, C., Lundrigan, S., & Ph, D. (n.d.). David canter - spatia patterns of serial murder Spatial Patterns of Serial Murder : An Analysis of.
- Rengert, G. F. (2004). The journey to crime. In G. Bruinsma. *Punishment, Places and Perpetrators: Development in Criminology and Criminal Justice Research, 169–181*.
- Rengert, G. F., Piquero, A. R., & Jones, P. R. (2006). Distance decay reexamined. *Criminology, 37*(2), 427–446. <http://doi.org/10.1111/j.1745->




9125.1999.tb00492.x

- Rossmo, D. K. (2000). *Geographic Profiling*. CRC-Press.
- Snook, B., Taylor, P. J., & Bennell, C. (2004). Geographic profiling: the fast, frugal, and accurate way. *Applied Cognitive Psychology*, 18(1), 105–121. <http://doi.org/10.1002/acp.956>
- Trotta, M. (2015). Modelling serial offenders' spatial behaviours: new assumptions for geographic profiling.
- Turner, S. (1969). Delinquency and distance. *Delinquency: Selected Studies*, 11–26.
- White, C. R. (1932). The relation of felonies to environmental factors in Indianapolis. *Social Forces*, 10, 498–509.
- Wiles, P., & Costello, A. (2000). The “Road To Nowhere”: the Evidence for Travelling Criminals. *Home Office Research Study 207*, 60.

ANEXO G

INDICIO DE CALIDAD DE LA TESIS DOCTORAL

(ARTÍCULO CIENTÍFICO)



Crime beyond the edge: development of a tool to correct the edge effect on crime count

Daniel Salafranca Barreda, Diego J. Maldonado-Guzman & Patricia Saldaña-Taboada

To cite this article: Daniel Salafranca Barreda, Diego J. Maldonado-Guzman & Patricia Saldaña-Taboada (2022) Crime beyond the edge: development of a tool to correct the edge effect on crime count, *Annals of GIS*, 28:3, 279-292, DOI: [10.1080/19475683.2022.2052748](https://doi.org/10.1080/19475683.2022.2052748)

To link to this article: <https://doi.org/10.1080/19475683.2022.2052748>



© 2022 The Author(s). Published by Informa UK Limited, trading as Taylor & Francis Group, on behalf of Nanjing Normal University.



Published online: 20 Mar 2022.



Submit your article to this journal [↗](#)



Article views: 1541




View related articles [↗](#)



View Crossmark data [↗](#)

Crime beyond the edge: development of a tool to correct the edge effect on crime count

Daniel Salafranca Barreda^a, Diego J. Maldonado-Guzman ^b and Patricia Saldaña-Taboada^c

^aCrímina Center, University Miguel Hernández, Elche, Spain; ^bDepartment of International Public, Criminal and Procedural Law, University of Cádiz, Cadiz, Spain; ^cDepartment of Criminal Law, University of Granada, Granada, Spain

ABSTRACT

The edge effect is a problem that can alter the results of some analyses, such as counting crime within a given geographic area. This article introduces a tool developed for *ArcGIS* toolbox, (*ArcGIS Geographic Information System*) to correct the border issues when using an aggregated crime data to artificially bounded space analytical units. It uses a method which considers those points located near the edge of the analysis unit, and avoids increasing the number of criminal points by assigning a value according to the distance of the edge. For this purpose, two functions based on decay with distance can be chosen: normal and linear. In order to show the performance of the tool, a sample of theft data occurred in 2016 in each census tract of Barcelona (Spain) district was used. These results show remarkable differences in the number of thefts in each census tract, before and after applying the edge correction. Some of the census tracts even went from experiencing no theft at all to having 5.5 or 4.5 incidents after correcting the edge effect. Finally, to demonstrate the benefits of the proposed tool, other strategies traditionally used as a solution for the edge effect were used. Then, the results are compared with those previously obtained.

ARTICLE HISTORY

Received 10 March 2021
Accepted 1 March 2022

KEYWORDS

Edge effect; *ArcGIS* toolbox; aggregated crime data; artificially bounded space; counting crime

1 Introduction

The disciplines responsible for the study of crime recognize that the criminal phenomenon can be understood and explained much more adequately if its geographical component is taken into consideration (Galdón Clavell and Pybus Oliveras 2011). Technological improvement and the development of Geographic Information Systems (GIS), from the 1990s, turned crime mapping and bounded space analysis into much simpler tasks that have improved over the years until today. In addition, the development of a set of integrated theories within environmental criminology, provided the crime mapping with a theoretical underpinning, explaining the results obtained from analysing the geographical and temporal component of crime.

In geographic crime analysis, point mapping is the most common way of depicting incidents. However, although this information is more precise regarding the exact location where the crime occurred, sometimes the crime analyst may have an interest or need to represent the data for an area in a summarized form (Harries 1999). In the latter case, the maps are obtained by aggregating the information to specific geographical units (municipalities, districts, neighbourhoods, census tracts, etc.).

For example, a quite usual type of cartographic representation of aggregated data are choropleth maps. Although their use for communicating the distribution of spatial phenomena has been extremely popular (Wei et al. 2017), it has also been the most misinterpreted and incorrectly produced type of map, of all the maps used most frequently (O'Sullivan and Unwin 2010). Though, applied to crime analysis, these maps represent, in a highly visual way, the amount of crime concentrated in each unit of analysis (a neighbourhood, for example); those units are not natural, as their boundaries are designed for administrative, policing, or political purposes.

Thus, a series of problems arise from using study areas whose boundaries are artificial, such as the so-called edge problem (Murray et al. 2001), which is one of the limitations to be considered in the ecological study of crime. The edge effect is present in those investigations that do not have the capacity to consider behaviours, objects or events that occur outside the studied geographic region, that is, beyond the limits of that region (Rengert and Lockwood 2009, 117). This problem would appear, according to Cruz Rot (2006), when points that are located outside the limits of the study area are not considered to estimate the characteristics of a point process. Therefore, it is suggested that

this problem has to be addressed, since ignoring its effects means omitting that any geographic distribution or spatial interaction occurring within the unit of analysis, may extend beyond its boundaries (Gao et al. 2017).

In this sense, it is a serious mistake, in the geographic analysis of crime, to assume, for example, that crime hotspots (drug sales points, gas stations or nightclubs, for instance) located near the artificial boundary that separates one neighbourhood from another, will only have a criminogenic effect in the neighbourhood where they are located, without extending that effect beyond the boundary that separates that neighbourhood from the adjacent one.

Although the edge problem is present at all scales of spatial analysis, its consequences are accentuated when small geographic units, such as census tracts, are used, as the probability of points being located close to the axis is considerably higher. In the context of the geographical study of crime, these consequences can be classified into two types: the effects on some spatial crime analysis methods and the consequences on the estimates of incident numbers in each area.

Regarding the first type, the border issue can alter the results of methods that analyse crime concentration patterns. This is because if points located outside the boundaries of the studied area are excluded from the analysis, a series of events are ignored preventing the real distribution of the phenomenon from being recorded (Rengert and Lockwood 2009). The border issue also alters the calculations of the nearest neighbourhood index, so all statistical tests that employ such an index in their calculations will be equally sensitive to the edge effect. For example, in geographic profiling of crime, the CGT formula proposed by Rossmo (2000) is composed of the parameter B, which is calculated with half the average of the nearest neighbour index. Thus, the geoprofiling results in this case are sensitive to the edge effect.

Concerning the second type, the edge effect alters the results of operations to count the number of points located within each unit of analysis (e.g. a census tract). This may have negative repercussions in studies that use the number of crimes within an area as a variable, since the calculation of that number may be biased. Despite the fact that the polygon point counting technique is the most commonly used (Murray et al. 2001), such operation, available in several GIS such as ArcGIS or QGIS, ignore the effect that a crime event occurring near the edge (or even on the edge), separating one unit of analysis from another, might have on the adjacent unit (Zhang, Suresh, and Qiu 2012). Thus, when a layer of crime points is aggregated to a layer, for example, of census tracts, such aggregation considers

the point as an event occurring in a single location (the unit of analysis in question delimited by the edges). In this way, crime scenes occurring any closer to the border of one unit with another are considered to be exclusive to one unit. Figure 1 exemplifies this issue.

Aware of the consequences of the edge effect, several authors have proposed a number of possible solutions. Examples are: the use of Kernel density maps as an alternative to other edge-sensitive methods (Ratcliffe 2010), the use of buffer zones around the study areas (Rengert, Ratcliffe, and Chakravorty 2005; McCord and Ratcliffe 2007; Zhang, Suresh, and Qiu 2012), the use of straight lines with edge sections to know if points are located within the polygon (Olaya 2010), the use of simple methods based on omitting those points close to the boundary of one unit with another (Rengert and Lockwood 2009), or more complex solutions such as weighting points close to the edge (Ripley 1988). A more detailed explanation of some of these and other solutions can be found in Cruz Rot (2006) and in Goreaud and Pélissier (1999)

However, while attempts have been made to overcome the edge problem, the above proposals also have several limitations. For example, using kernel density as a solution does not allow to correct the counting incidents problems in choropleth maps, as kernel density does not give as an output a value to be aggregated to a spatial unity. For its part, the use of buffer zones is not a solution to the edge problem per se, since the real need is for the data to be spatially continuous (Rengert




Figure 1. The image shows how the incidents are quite close to the border with the other neighbourhood, a border that does not really exist in the geographic space. For this reason, it is necessary to consider that each of these crimes has also occurred in some way in the adjacent neighbourhood, since the distance that separates them is minimal, and because such boundaries do not exist. As a consequence, the crime that occurs near the border will have some effect on the adjacent neighbourhood. Own elaboration.

and Lockwood 2009). In addition, this approach greatly increases the actual number of crimes that have occurred, as all incidents within the buffer are recounted in adjacent units. Figure 2 exemplifies this method to illustrate this limitation. On the other hand, the proposal to ignore incidents close to the edge produces a loss of information, which will be more serious when the number of points to be analysed is small. Finally, the use of straight lines cutting the axis is problematic when the ray traced touches the contour of the polygon or when the point is located right on the edge of the analytical unit.

Due to the consequences of the edge effect on geographical analyses in general and on spatial studies of crime in particular, and given the limitations of the suggested solutions, this article proposes a fresh method for correcting the edge effect that has been incorporated into the tool developed for the ArcGIS software. This tool makes it possible to automate the method presented. The process consists of duplicating the points close to the axis and weighting them using two possible decay functions with distance. This method overcomes the problems in obtaining the number of crimes in artificially delimited geographic units, since it allows computing the same crimes in two different adjacent units without increasing the real number of crimes. Likewise, the proposed method can be applied at any scale regardless of the analytical unit. It is also capable of




Figure 2. Example of the buffer zone method. The central polygon corresponds to the census tract in question. A buffer of 250 metres is created around the polygon (shaded area). The number of crimes occurring within the census tract is 37. However, in the adjacent area created with the buffer, 410 points are located. Therefore, these points at 250 metres from the axis are considered to have occurred within the census section, and so, instead of 37 crimes, 447 are considered to have occurred within the unit of analysis. Own elaboration.

detecting the limits of the study region, and its application is simplified by the creation of an ArcGIS tool that is available to the reader.

The article is structured as follows: first, the proposed method to correct the edge problem is described, and the tool developed to automate all the steps described is introduced. Next, the results obtained before and after applying the proposed correction on theft crimes in the Ciutat Vella district of the city of Barcelona (Spain) are explained. Simultaneously, these results are contrasted with those derived from applying as a solution a Kernel Density Estimation (KDE) and the creation of buffer zones. The last section corresponds to a discussion of the method's contributions and a proposal for future research.

2. Method

2.1. Edge effect correction

The proposed method solves the edge effect by considering two factors. The first is the distance of the points to the axis, for which a distance in metres (to be chosen by the analyst) must be determined between each crime point and the edge of the analytical unit where that point is located. In order to select the best distance by which all points located below it are doubled, we suggest using the standard deviation (SD) of the distance between all the points in the sample and the nearest edge. This is similar to the nearest neighbourhood index, but instead of using the nearest average distance between all the points in the sample, the distance between all the points and their nearest edge is employed. The SD criteria is used to calculate the bandwidth size in a fixed kernel (Levine 2010). Thus, once the SD of the points-to-edge distances have been calculated, we suggest using this value as a distance criterion to select the points to be doubled. This distance-chose criteria allows to correct the border issue in any scale regardless of the size of the unit of analysis.

The criteria used to determine the best distance as a threshold when accounting the edge effect seem not to be based on any theoretical or statistical support. For example, Ewers and Didham (2006) shows different ways used to establish the critical percentage in order to determine the extension of the edge effect. The cited authors warn that no justification is given to select each of these criteria. Probably the way in which the optimal distance is determined is adapted to each solution purpose. As an example, Zhang, Suresh, and Qiu (2012) establish the buffer area size in two miles because that is the length of two inner city blocks, that is, the spatial unit of analysis they employ in their research. For its part,

the circumference-based Ripley's solution for the edge effect takes the distance between one point i and its nearest neighbour point to draw a circumference round the point i , using the proportion of the circumference within the study region as the weighting factor.

In our case, we choose the SD as a distance criterion, since it allows the analyst to take into account the average distance between all the points in the sample and their nearest edge. The SD has been selected over other possibilities (i.e. the mean) in order to deal with the extreme values.

Choosing an example of 100 metres (i.e. supposing that $SD = 100$), all crime events located within this distance will be duplicated to the adjacent unit of analysis (Figure 3). In case of one point is less than 100 metres from several unit of analysis, it would be doubled to the nearest one (in terms of distance).

Using only the first factor to fix the edge effect would result in an increase in the actual number of crime incidents, since each point near the axis is doubled according to the distance determined by the analyst. This means that if there are 1000 crimes in the original dataset and 300 of them are close to the edge (below the chosen distance), the total number of crimes would be 1300. Therefore, in order to correct this problem, the second factor indicated, i.e. the decay function for the duplicate point weighting, must also be taken into account. This procedure ensures that each duplicated point does not have a value of one, instead, this value is the result of a weighting estimated according to the distance of the point from the axis.

In this way, continuing with the previous example, if the original data set contains 1000 crimes and 300 are close to the edge (below the established distance), the total number of points is 1300, but the sum of all of them will be 1000 (the original number of criminal events in the sample). Despite Bailey and Gatrell (1995) claim that the choice of the weighting algorithm is not a crucial decision in obtaining the results, we have included the possibility of choosing between two functions for weighting the duplicate points that the method offers: the linear function and the normal function. The first is the simplest and implies that the value assigned to the point is constantly reduced as the distance from the point to the axis increases. Thus, the maximum value is located at the point and decreases steadily to a value of zero. On the other hand, the normal function is a curve (see Figure 4) in which the points obtain a smaller value as the distance to the edge decreases in an unequal manner.

Nevertheless, several adjustments have been made to the two weighting functions. The proposed method has inverted the two functions so that the value of the point decreases as the distance from the axis decreases (Figure 5). The reason for this inversion is that the effect of crime on the original analytical unit decreases as the point approaches the edge. It is then hypothesized that placing the point at the centre of the unit of analysis is not the same as placing it on the border with the adjacent unit. In the second case, the effect is distributed between both units.




Figure 3. Example of point mirroring to the adjacent unit of analysis. The points within the box are less than 100 metres from the edge, so they are duplicated in the adjacent census tract. Own elaboration.




Figure 4. Linear (grey) and normal (black) distance decay functions. Own elaboration.

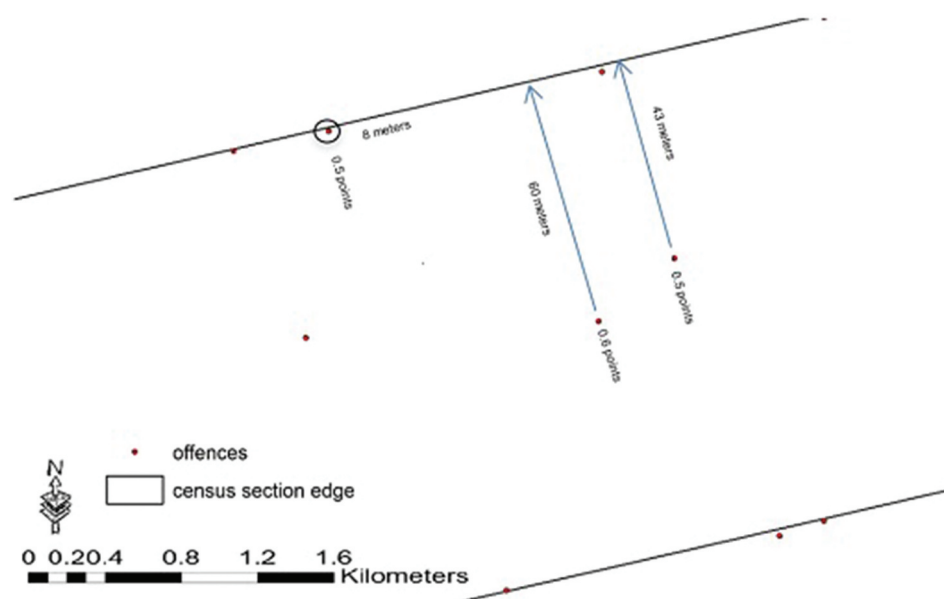


Figure 5. Point weighting using the linear function. With a set distance of 100 metres, all points within 50 metres of the edge will have a value of 0.5. Above 50 metres, the values of each point will depend on the distance to the axis. Own elaboration.

In addition to inverting the function, another adjustment has been made so that all points below half the selected distance have the same value (0.5) in both units of analysis (McCord and Ratcliffe 2009). This prevents the possibility of the original point having a lower value than its duplicate counterpart. For example, if a distance of 100 metres and a linear function have been entered, all points below 50 metres (half of 100) will have a value of 0.5 (both the original point and the duplicate point). In the case of points above half the set distance (but not exceeding it), the value of those is determined by the

distance to the axis. For example, with a set distance of 100 metres, a point located 60 metres from the edge will have a value of 0.6 (and its duplicate counterpart will be worth 0.4). For a point located 75 metres from the edge will have a value of 0.75 (and its duplicate counterpart will be worth 0.25 points). Figure 6 shows an example with a distance set by the analyst of 100 metres.

As specified above, the weighting functions serve to solve the problem of multiplying the number of original crimes. However, there may be another limitation when, beyond the border of a unit of analysis (census tracts in

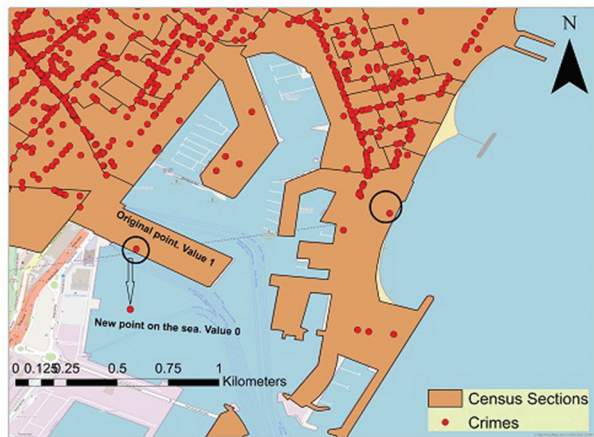


Figure 6. The points near the edges where there is no unit of analysis on the other side are duplicated, but do not lose their original value of one (1). Own elaboration.

this paper), there is no region under study. The method proposed here is designed to detect this type of situation. This is especially important when the sea is beyond the axis. Regarding the case of the study region in this article (see Figure 7), some census tracts in the Barceloneta quarter are surrounded by the sea. Here, the points close to the edge would lose their true value (value = 1), which would not be correct, since, although they are very close to the edge, there are no adjacent areas where they could deploy their effect. For this reason, even if the proposed method doubles the points,

in the cases just described the duplicated point over the sea would have a value of zero, so the original point still retains its initial value, i.e. a value of one (Figure 7).

The tool detects the end of the studied region by noticing that beyond the edge there is not another polygon, i.e. that there is not a continuous surface. So, when beyond the edge there is the sea or another obstacle which interrupts the continuity (or the end) of the studied area, the points near this edge will not be considered for being doubled. As the tool proposed in this paper is designed to correct the border issue when counting points in aggregated spatial units (polygons), the tool has been programmed to detect the end of the studied area (artificial areas), not to detect discontinuities in the physical space (natural areas). This is because it is not important where the point is exactly located, but ensuring that it is actually located inside the given polygon.

It is also important to point that the tool always doubles the point to the nearest adjacent area, i.e. to the nearest neighbouring unity of analysis. This way of working make it necessary to think on two very strange but possible situations. Firstly, when analysing data aggregated to very small size areal unities, one point could be near to more than one contiguous area, but the point will be only doubled to the next one (these which is nearer the original area which contains the point close to the edge). Secondly, although highly difficult, one point could be located at the same distance (within

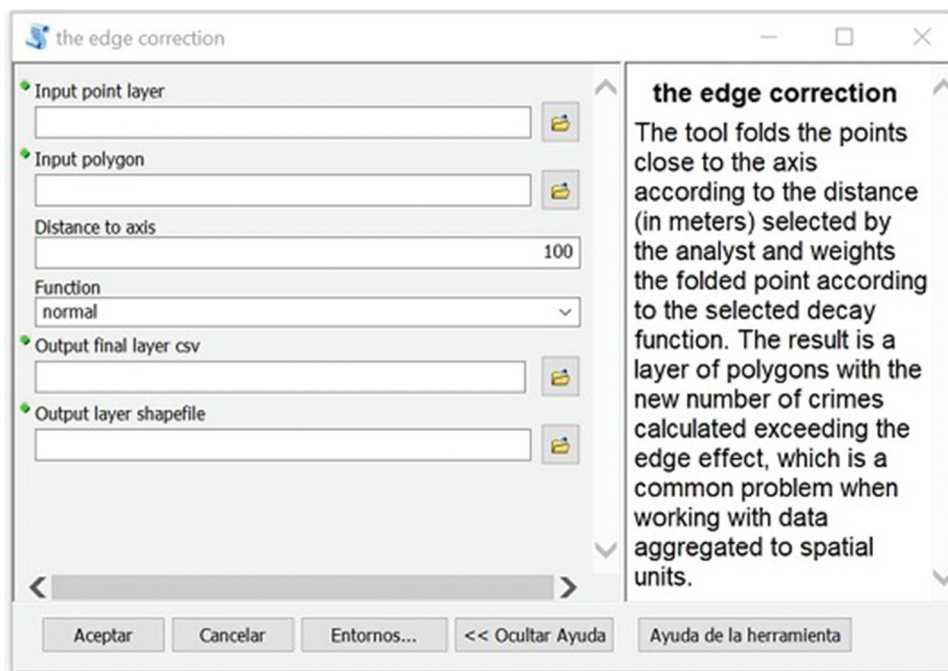


Figure 7. Interface of the tool "the edge correction" developed for the correction of the edge effect.

that specified by the analyst) from not only one but several neighbouring areas. In this case, the tool will not double this point to any of the four areas, but will give the original point the value of 0.5.

2.2. Development of an ArcGIS toolbox to correct the edge effects

The method described so far can be complex if performed manually. Therefore, we have developed a tool for ArcGIS that automates the whole procedure and allows us to obtain the number of offences in each unit with the correction of the edge effect (Figure 8). More specifically, a script has been developed in R language that will be incorporated into ArcGIS using R-Integration (Appendix 1). The final tool as well as the test data and the installation manual are freely available.¹ The obtained result is a file in shapefile format containing the number of offences in each unit after correction of the edge effect.

The data used to show the edge effect correction are the theft crimes occurred in 2016, in the census tracts that constitute the Ciutat Vella district of the city of Barcelona (Spain). The file with the georeferenced information of the thefts was obtained through the Department of Interior of the Generalitat de Catalunya,² and refer to all theft crimes occurred in the public streets of Barcelona that were recorded by Mossos d'Esquadra. The coordinates contained in the file were geographical (longitude and latitude).

In order to obtain the locations of the criminal events that occurred only in the Ciutat Vella district, a definition by query was made. As a result, the total number of thefts committed in 2016 was of 6558 crimes in Ciutat Vella (District 1). For its part, the layer of polygons corresponding to the census sections was obtained through

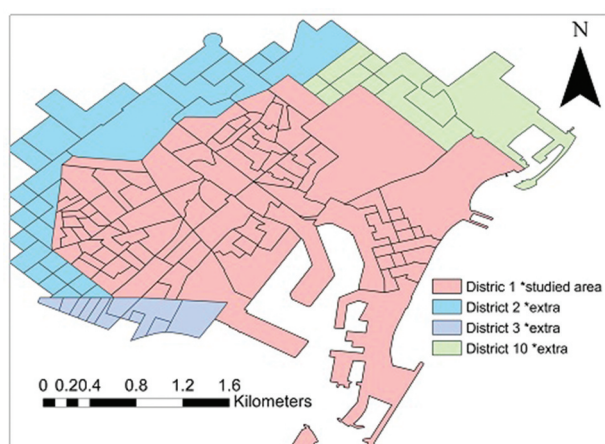


Figure 8. Census sections of the Ciutat Vella district together with some extra census sections of the adjacent districts. The sum of both layers constitutes the study area in this article. Own elaboration.

the Cartographic and Geological Institute of Catalonia. To obtain the census sections belonging to the district under study, a definition was made by query. However, some census sections belonging to districts number 2, 3 and 10 were included. This operation was carried out so that the incidents located on the edge of the Ciutat Vella census sections, that had no more adjacent sections, were considered for the methodology and allowing the duplication of the point (Figure 9).

Before showing how the tool has been developed and the results of applying it, a guide with several steps is shown to facilitate using the tool and to remember the two decisions the analyst has to make. As is detailed in steps two and three in Figure 6, the analyst has to decide two parameters: (i) what points near the edge wants to be doubled (choosing the distance to the axis) and (ii) the distance-decay function to weight the value of the points (choosing between a normal or lineal function).

4. Results

In order to demonstrate the benefits of the proposed method, the results obtained before and after applying the edge effect correction are compared in Figures 10 - 12. The first one shows the number of theft crimes for each census tract using the traditional 'points-in-polygons' method, while Figures 11 and 12 show the results of correcting the edge effect using the linear and normal functions, respectively. ArcGIS Desktop 10.4.1 GIS was used for this purpose. As the SD of the average distance between all crimes and the edge of the studied region is 48, we double all points situated at or below 48 metres from the neighbourhood edges.

Figure 10 shows the results of applying the traditional operation that counts the number of points within each polygon. In this case, the number of crimes is integer and the census tract with the highest concentration of crime has a total of 1185 thefts. The following map (Figure 10) shows the results of applying the edge correction using the linear decay function.

It can be confirmed that, due to the weighting effect of distance, the number of crimes after applying the edge correction becomes decimal. In addition, the census tract that in Figure 6 had the highest concentration of crimes with a total of 1185 thefts now yield a result of 1207.26 crimes. Figure 11 shows the results of applying the edge correction using the normal type of decay function. Again, the results are decimal numbers. The census tract that in Figure 10 had a higher crime concentration with a total of 118 thefts, now yields for the normal function a result of 1211.80 crimes. This is a consequence of incorporating the points too close to the edge of the other adjacent census tracts.

- 1 Make sure both the points and polygon layers have the same projection (coordinate system).
- 2 Select what points would have to be doubled to adjacent units. To do so, please calculate the SD of the distances between all points and the edge of the spatial units. When using different scales, calculate the SD for each of them to select what points should be doubled in each case.
- 3 Choose the distance-decay function to weight the value of the points doubled. There is not a remarkably difference when using one or another.
- 4 Select the folder in which you want to save the shapefile and csv files.
- 5 Execute the tool. When finishing running, a shapefile appears. The row called "number_all" contains the results after using the tool.

Figure 9. Steps to be followed to select the parameters of the tool and run it.

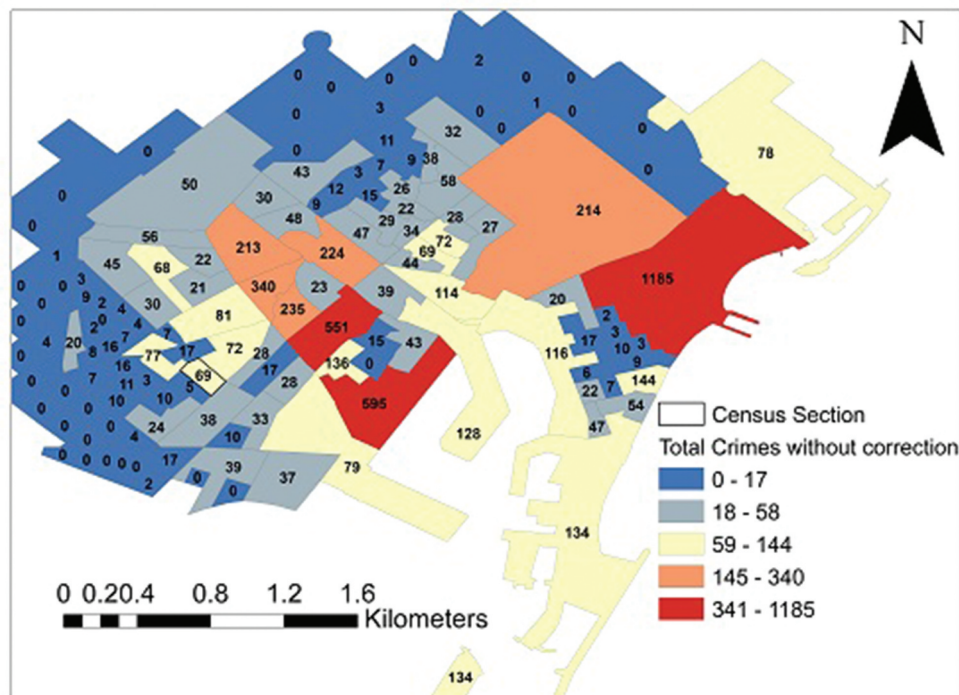


Figure 10. Number of crimes per census tract without edge effect correction. Own elaboration using ArcGIS 10.4.1.

To facilitate the comparison of the results, Table 1 shows the number of crimes for some of the census tracts in the study region. Those that represent the different possible outcomes have been chosen: census tracts in which the number of incidents increased after applying the correction, census tracts in which the number of incidents decreased after the correction, and census tracts that went from experiencing no crime to having several crimes.

The Table 1 shows how several census tracts experience a substantial change in the number of thefts after applying the edge correction. For example, census tract D had a total of 79 crimes after performing the polygon point count operation without correcting for the edge

problem. After running the tool, the number of crimes for this census tract increased to 372.14 incidents for the linear function, and to 240.93 crimes for the normal function. The opposite case can be observed in census tract A, where the volume of crimes decreased considerably (222.9 less crimes for the linear function and 167.13 less crimes for the normal function). At the same time, section F, which initially contained no incidents, now has 4.5 crimes both for the linear and normal functions.

In order to compare the results obtained by the tool with those generated by using a KDE and the buffer-based solutions, Figures 13 -16 are shown together with Table 2. It should be recalled that the buffer-based

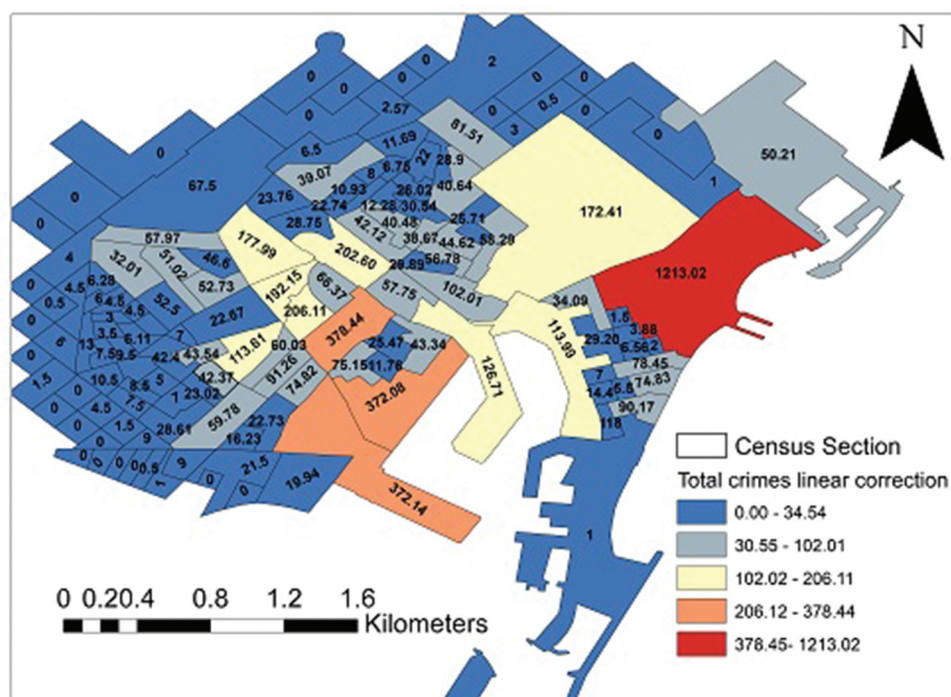


Figure 11. Number of crimes by census tract after applying the edge effect correction with the linear function. Own elaboration using ArcGIS 10.4.1.

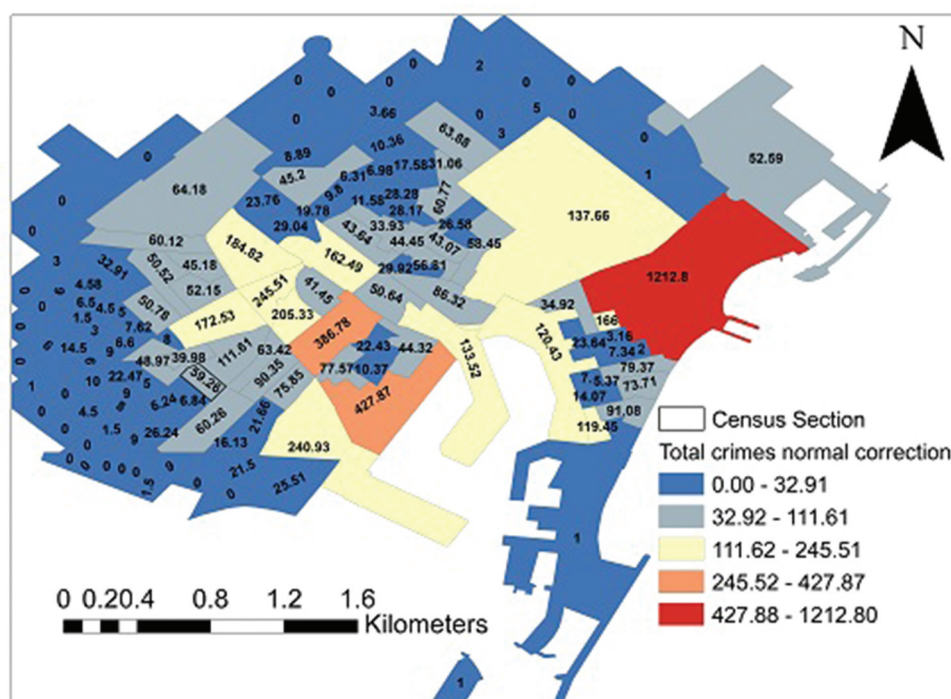


Figure 12. Number of crimes per census tract after correction of the edge effect with the normal function. Own elaboration using ArcGIS 10.4.1.

solution consists in creating an extra zone of a given size around the boundaries of each analysis unit (see Figure 2). The points located above this buffer zone are incorporated into the analysis unit in question to take

them into account. This implies the need to create a buffer for each analytical unit and to count the number of points in each buffer. As the process is time-consuming, we compare the results for the census tracts




Figure 13. Results after applying the correction with the linear function.




Figure 14. Results after applying the correction with the normal function.




Figure 15. Results without applying any correction.

of one of the four neighbourhoods that make up the study region. In order to better compare the two solutions, the buffer size selected was 48 metres, the same distance that was introduced in the tool to correct the edge effect. Of the total 6558 thefts that occurred in the entire study region, 2091 were recorded in the Raval neighbourhood and on the edges of the immediately adjacent census tracts. The results of applying the different solutions to the Raval crimes can be seen in the following figures. Results of applying linear correction, normal correction, no correction and the buffer correction are shown in Figure 13, 14, 15 y 16, respectively.

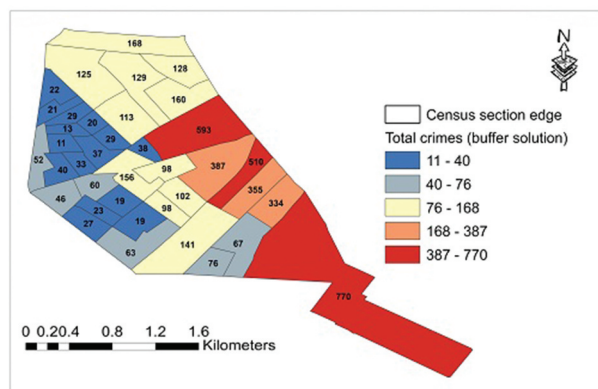
Looking at the figures above, the number of crimes in each census tract after applying the buffer-based solution increases dramatically. This does not occur when applying the weighting solution that we propose in this article. With the tool presented here, only two of the census tracts have experienced a noticeable increase in the number of crimes because a high number of points were closely located to the axis in adjacent census tracts. However, the differences in the number of points when the buffer solution is applied are much more prominent. For example, one of the census tracts went from 79 thefts to 770 thefts after incorporating the buffered points. Therefore, the original number of points in the data has increased significantly. However, the application of the method we propose keeps the original number of crimes analysed accurate. Table 2 shows this. Note how the application of the buffer has almost quadrupled the number of incidents.

A strategy which is not sensible to the border issue is the KDE. When it is used, KDE produces a continuous surface considering all the points regardless of the edge of the spatial unit of analysis. However, the KDE solution is not useful when the analyst is interested in getting a value (for example, the number of crimes occurred) to be aggregated to a spatial unit (a census section, for example). This is because KDE only creates a heat map overcoming the artificial edges but does not give a value which could be used as a variable (for example, the amount of crime in each area).

Figure 17 shows a KDE applied to our crime data. It can be seen that we only are able to know where the hot spots are concentrated, but we do not get a crime count in each census section as a result. A possible alternative to get a value which could be aggregated to an area is using KDE by dividing the study area into cells. Each cell has a specific KDE value (z-value). Thus, by selecting the cells contained inside each spatial unit (polygon) we can calculate a value (the average z-values) that could be assigned to the specific unit (Xu, Pennington-Gray, and Kim 2018; Maldonado-Guzmán 2020). Figure 18 shows

Table 1. Comparison of the resulting number of crimes in each spatial unit.

Census Section	No edge correction	With linear correction	With normal correction
A	595	372.08	427.87
B	1185	1213	1212.8
C	50	67.5	64.18
D	79	372.14	240.93
E	214	172.41	137.66
F	0	4.5	4.5

**Figure 16.** Results after applying the buffer-based correction.**Table 2.** Total number of crimes resulting from each solution applied.

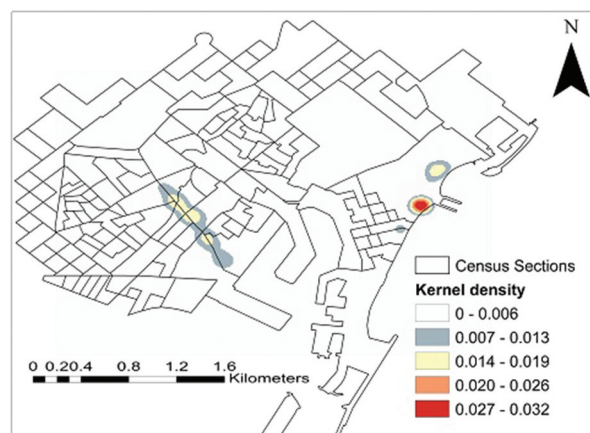
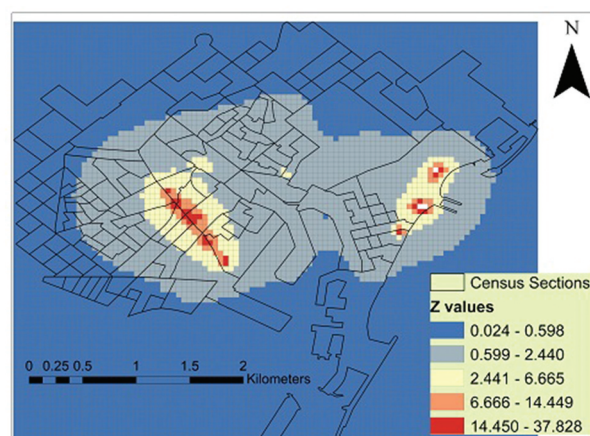
Number of crimes without correction	Number of crimes with normal function	Number of crimes with linear function	Number of crimes with buffer solution
2091	2091	2091	5112

how the study area has been divided into 17,300 cells, each of them with a size of 100 square metres. Figure 19 shows the values of KDE in each cell. Thus, the value for the census section in the sample is 8.33.

However, doing the previous process manually is quite time-consuming. For example, to calculate the value for each spatial unit it is necessary to carefully draw the contours of the polygon in order to only select the cells inside it for the average calculation. Unless the analyst uses a software to compute this process automatically, repeating this method for each polygon manually can be tedious, especially when the number of spatial units is high. Moreover, the same cell can be contained by two or more polygons, and also some cells usually are not entire inside the polygon, so its whole value should not be counted when calculating the average value of KDE.

5. Discussion

This paper proposes a solution to the edge problem when counting crime incidents in artificial units. For this purpose, a tool has been developed

**Figure 17.** KDE of theft crimes occurred in 2016 in Ciutat Vella district. The bandwidth chosen has been 9,5773200000249E-05 (that suggested by default considering the data introduced).**Figure 18.** KDE using *Crimestat* software. With a fixed bandwidth of 9,5773E-05, the study region has been divided in 13,700 cells of 100 square metres each.

in ArcGIS that allows to apply such a solution automatically. By doubling the point to the adjacent unit in a weighted way, the results are more in line with the spatial reality of the criminal phenomenon. In this way, a fresh methodology is presented that overcomes the limitations of other approaches that have also been used to solve the edge effect when counting point data.




Figure 19. Example of calculating the average value of crime density to add it to a specific census tract. The numbers inside the polygon are considered to calculate the average value.

The proposed method for solving the border issue shows a number of advantages over other proposals. First, it makes it possible to compute the same crime in two different adjacent units, but without increasing the actual number of incidents occurring. Second, the procedure can be applied at any scale, regardless of whether the analytical unit is a country, city, neighbourhood or census tract. The only necessary thing is to adapt the distance for the new scale.

Third, this method can detect when the study region ends. Either because there are no other units on the other side of the boundary or because of the presence of the sea, the value of the point near the edge is automatically corrected. Lastly, this procedure achieves a sort of continuous surface in the territory, since the occurrence of a crime near the border of a census tract does not prevent that crime from being taken into account in the adjacent census tract.

Moreover, beyond the improvement in obtaining the number of crimes compared to the traditional point-in-polygon method, the tool can be useful for the analysis of fear of crime, since it considers the effect that a crime committed in one neighbourhood may have on the neighbourhood next door. The way by which crime incidents are counted after applying the tool makes it possible to consider those crimes that occurred in proximity to, but out of, the study region. For example, Maldonado-Guzmán et al. (2021) point out that in Barcelona the Besós quarter has

high levels of fear of crime, although it has low levels of crime rates. The mentioned authors argue that this neighbourhood is adjacent to the Mina quarter, an area which belongs to another municipality different from Barcelona and that it has high levels of crime and social and physical disorder. If crime data of the Mina quarter is incorporated into the Barcelona crime data, the correction of the border issue by using the tool allows to consider crime incidents committed out of but near the limits of the study region, then improving the understanding of the relationship between crime concentration and fear of crime.

In order to weight the crime incident, depending on its distance from the axis, two decay functions with distance have been used. The results of applying one or the other are quite similar, being consistent with the results obtained by Ratcliffe and Taniguchi (2008) in their analysis. However, future research should compare the results generated by the tool as a function of the type of crime analysed and the spatial distribution pattern of the points. In this way, it could be revealed whether the use of one decay function or another is more appropriate based on the data to be analysed. Also, future modifications could be made to adapt the distance between the points and the edges depending on the area size of each spatial unit. Doing so, the tool could automatically adapt the best threshold distance to select which points are doubled, thus working as an adaptive bandwidth

Despite the improvements cited above, the tool purposed in this paper has some limitations which should be under consideration. Firstly, the current version of the tool only takes into account the chosen distance from the point to the nearest edge as a weighting factor. Nonetheless, also the size of both unities of analysis, that which contains the original point and that in which this point will be doubled, should be considered for the point weighting. Doing so it is important because when working with irregular boundaries, the influences on the adjacent spatial unit for the points are not equal in size, even though the two points on one side of the edge and the other are located exactly the same distance from the edge and within the selected distance by the analyst. Thus, futures developments of the tool need to incorporate the differences in the size areas together with the distance weighting criterion.

Secondly, the results obtained after using the tool are not integer numbers. This could limit the use of the results as dependent variable when using count regression models such as Poisson or Negative Binomial models, both typically used in the analysis of spatial crime data (Osgood 2000; Hilbe 2011). However, this limitation can be easily solved if the analyst rounds the number of crime. Operating by this way is not a problem, as the decimals numbers are so small that the rounding process does not increase the total amount of original points in the sample. Once the analyst has rounded the results after correcting the edge effect, an offset variable could be used to consider the population or areal unity size in which the data is observed (Hilbe 2017). This process allows to calculate the crime rates or densities instead of using the raw number of incidents. Several statistic packages such as SPSS or STATA include this option.

Thirdly, the analyst might be interested in choosing specifically which points within the distance specified have to be doubled to the neighbouring areas. The current version of the tool does not allow to do that automatically, but the analyst can use one of the csv files the tool generates to find which points have been doubled and, of all of them, which would not have wanted to be doubled. Then, the analyst can create a layer with those selected points and make a spatial join between the original layer and the layer containing the points which have been removed from the doubled incidents list.

In spite of the limitations above discussed, the tool makes improvement to the process of counting points in polygons skewed by the edge effect. Until the present, analysts made the traditional spatial join to get the number of points within polygons without be worried about such effect. The tool developed here allow the analyst to correct this problem in a more automatically and exactly way. Also, it is

worth to note that the tool has been developed to obtain a general solution to the edge effect according to the needs that the authors have found in their research. It is expected that with the opportunity to offer this tool to other analysts, further improvements and modifications will be incorporated as other professionals have other needs arising from their own investigations. The authors are delighted to receive the suggestions of the analysts who use the tool, in order to adapt the tool to the real problems that these analysts encounter in practice.

Bibliographical note

Daniel Salafrañca-Barreda is PhD candidate at the University of Miguel Hernández and a member of the Atypical Homicide Research Group. His research interests are in crime mapping and geographic profiling.

Diego Maldonado-Guzmán is a PhD Candidate and predoctoral fellow at the Department International Public Criminal and Procedural Law of the University of Cadiz, Spain and a member of Penal system, criminality, and security group (SEJ-378). His research interests are in geographical crime analysis, social disorganization and crime, geographic profiling, and online child sexual abuse.

Patricia Saldaña-Taboada is a PhD candidate and predoctoral Fellow at the Department of Criminal Law of the University of Granada, Spain. Her research interest are in cryptocurrencies and digital crime, cryptomarkets and crime and place.

Notes

1. The link to download the tool is: <https://github.com/utm30web/Edge-effect.git>
2. Download available on the website of the Cartographic and Geological Institute of Catalonia from this link <http://bit.ly/2oCDRy3>

Disclosure statement

No potential conflict of interest was reported by the author(s).

ORCID

Diego J. Maldonado-Guzman  <http://orcid.org/0000-0002-5283-0634>

References

- Bailey, T. C., and A. C. Gatrell. 1995. *Interactive Spatial Data Analysis*. London: Longman.
- Cruz Rot, M. 2006. "Introducción al análisis de datos mapeados o algunas de las (muchas) cosas que puedo hacer si tengo coordenadas." *Ecosistemas* 15 (3): 19–39.

- Ewers, R. M., and R. K. Didham. 2006. "Continuous response functions for quantifying the strength of edge effects." *Journal of Applied Ecology* 43 (3): 527–536. doi:10.1111/j.1365-2664.2006.01151.x.
- Galdón Clavell, G., and M. Pybus Oliveras. 2011. "Crisis económica y gestión de la inseguridad ciudadana: Los mapas de delincuencia." *Revista Catalana de Seguretat Pública* 24: <https://www.raco.cat/index.php/RCSP/article/view/244856>
- Gao, F., W. Kihal, N. Le Meur, M. Souris, and S. Deguen. 2017. "Does the edge effect impact on the measure of spatial accessibility to healthcare providers?" *International Journal of Health Geographics* 16 (1): 46. doi:10.1186/s12942-017-0119-3.
- Goreaud, F., and R. Pélissier. 1999. "On explicit formulas of edge effect correction for Ripley's K -function." *Journal of Vegetation Science* 10 (3): 433–438. doi:10.2307/3237072.
- Harries, K. 1999. *Mapping crime: principle and practice*. Washington: National Institute of Justice. <https://www.ojp.gov/pdffiles1/nij/178919.pdf>
- Hilbe, J. M. 2011. *Negative binomial regression*. United Kingdom: Cambridge.
- Hilbe, J. M. 2017. "The statistical analysis of count data/El análisis estadístico de los datos de recuento." *Cultura y Educación* 29 (3): 409–460. doi:10.1080/11356405.2017.1368162.
- Levine, N. 2010. "Kernel Density Interpolation." In *CrimeStat: A Spatial Statistics Program for the Analysis of Crime Incident Locations* (v 3.3). Houston, TX: National Institute of Justice. <https://www.ojp.gov/pdffiles1/nij/grants/242960-242995.pdf>
- Maldonado-Guzmán, D. 2020. "Airbnb and crime in Barcelona (Spain): testing the relationship using a geographically weighted regression." *Annals of GIS* 1–14. doi:10.1080/19475683.2020.1831603.
- Maldonado-Guzmán, D. J., P. Saldaña-Taboada, and A. Miguel-Alvaro. 2021. "Spatial analysis of perceived insecurity in Barcelona: The role of adjacent neighbourhoods and psychosocial factors involved." *Anuario de Psicología Jurídica* 31 (1): 63–73. doi:10.5093/apj2021a7.
- McCord, E. S., and J. H. Ratcliffe. 2007. "A micro-spatial analysis of the demographic and criminogenic environment of drug markets in Philadelphia." *Australian and New Zealand Journal of Criminology* 40 (1): 43–63. doi:10.1375/acri.40.1.43.
- McCord, E. S., and J. H. Ratcliffe. 2009. "Intensity value analysis and the criminogenic effects of land use features on local crime patterns." *Crime Patterns and Analysis* 2 (1): 17–30. <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.364.6362&rep=rep1&type=pdf>
- Murray, A. T., I. McGuffog, S. Western, and P. Mullins. 2001. "Exploratory spatial data analysis techniques for examining Urban crime." *British Journal of Criminology* 41 (2): 309–329. doi:10.1093/bjc/41.2.309.
- O'Sullivan, D., and D. J. Unwin. 2010. *Geographic information analysis*. New Jersey: John Wiley and Sons. doi:10.1002/9780470549094.
- Olaya, V. (2010). *Sistemas de información geográfica*. <https://volaya.github.io/libro-sig/>
- Osgood, D. W. 2000. "Poisson-based regression analysis of aggregate crime rates." *Journal of quantitative criminology* 16 (1): 21–41. doi:10.1023/A:1007521427059.
- Ratcliffe, J. H. 2010. "The spatial dependency of crime increase dispersion." *Security Journal* 23 (1): 18–36. doi:10.1057/sj.2009.16.
- Ratcliffe, J. H., and T. Taniguchi. 2008. "Is crime higher around drug-gangs streets corners? two spatial approaches to the relationship between gang set spaces and local crime levels." *Crime Patterns and Analysis* 1 (1): 23–45. <http://ttaniguchi.net/wp-content/uploads/2014/08/Ratcliffe-Taniguchi-2008-Is-crime-higher-around-drug-gang-corners.pdf>
- Rengert, G. F., and B. Lockwood. 2009. "Geographical units of analysis and the analysis of crime." In *Putting Crime in Its Place. Units of Analysis in Geographic Criminology*, edited by D. Weisburd, W. Bernasco, and G. J. N. Bruinsma, 109–123. New York: Springerpp. doi:10.1007/978-0-387-09688-9_5.
- Rengert, G. F., J. H. Ratcliffe, and S. Chakravorty. 2005. *Policing illegal drug markets: geographic approaches to crime reduction*. New York: Criminal Justice Press.
- Ripley, B. D. 1988. *Statistical inference for spatial processes*. New York: Cambridge University Press. doi:10.1017/CBO9780511624131.
- Rossmo, K. 2000. *Geographic Profiling*. Miami: CRC Press.
- Wei, R., T. H. Grubestic, M. Manfredi, F. Mele, D. Amparore, G. Cattaneo, I. Morra, R. M. Scarpa, and F. Porpiglia. 2017. "An alternative classification scheme for uncertain attribute scheme." *Minerva Urologica E Nefrologica = the Italian Journal of Urology and Nephrology* 69 (4): 604–615. doi:10.1080/00330124.2017.1288573. *The professional geographer*.
- Xu, Y., L. Pennington-Gray, and J. Kim. 2018. "The sharing economy: a geographically weighted regression to examine crime and the shared lodging sector." *Journal of Travel Research* 58 (7): 1–16.
- Zhang, H., G. Suresh, and Y. Qiu. 2012. "Issues in the aggregation and spatial analysis of neighborhood crime." *Annals of GIS* 18 (3): 173–183. doi:10.1080/19475683.2012.691901.

ANEXO H

CÓDIGO FUENTE REDES NEURONALES

```

```{r,warning=FALSE}

library(dplyr)

library(readxl)

library(e1071)

library(caTools)

library(caret)

Data <- read_excel("H:\\TESIS_WORD\\[]
Merodeado_viajero\\FRRELANCER_2020\\FReelancer_V2.xlsx")

Data<-Data[,-1]

Data<-na.omit(Data)

Data$Commuter<-Data$`[30]Rango_canter` == "0"

Data$Marauder<-Data$`[30]Rango_canter` == "1"

standardiser <- function(x){
(x-min(x))/(max(x)-min(x))
}

Data[, -c(1:2)]<-lapply(Data[, -c(1:2)], standardiser)

set.seed(4182221)

idx<-sample(nrow(Data),nrow(Data)*0.8)

Data <- as_tibble(Data)

train<-Data[idx,-c(2)]

test <- Data[-idx,-c(2)]

library(neuralnet)

library(NeuralNetTools)

names(train) <- make.names(names(train))

dp<-"Commuter + Marauder ~"

model<- neuralnet(Commuter+Marauder~.,
data=train, hidden = c(3,5)

```

```
)
```

```
...
```

```
```{r}
```

```
plot(model, rep="best")
```

```
plotnet(model, rep="best")
```

```
olden(model,rep="best")
```

```
```{r}
```

```
```{r}
```

```
names(test)<-make.names(names(test))
```

```
prediction <- compute(model, test)
```

```
idx <- apply(prediction$net.result, 1, which.max)
```

```
predicted <- c('0', '1')[idx]
```

```
predicted<-factor(predicted)
```

```
cm<-table(predicted, test$X.30.Rango_canter)
```

```
cm
```

```
misClasificError <- mean(predicted != test$X.30.Rango_canter)
```

```
print(paste('Accuracy',(1-misClasificError)*100,"%"))
```

```
...
```

```
```{r}
```

```
library(dplyr)
```

```
library(readxl)
```

```
library(e1071)
```

```
library(caTools)
```

```
library(caret)
```



```

Data <- read_excel("H:\\TESIS_WORD\\[
Merodeado_viajero\\FRRELANCER_2020\\FReelancer_V2.xlsx")

g<-Data[-c(1:513),1]

Data<-Data[,-1]

standardiser <- function(x){
 (x-min(x,na.rm = TRUE))/(max(x,na.rm = TRUE)-min(x,na.rm = TRUE))
}

set.seed(4182221)

idx<-sample(nrow(Data),nrow(Data)*0.8)

Data <- as_tibble(Data)

train <- Data[idx,]

test <- Data[-idx,]

test[, -c(1:2)]<-lapply(test[, -c(1:2)], standardiser)

train[, -c(1:2)]<-lapply(train[, -c(1:2)], standardiser)

train <- train[,-c(2)]

test <- test[,-c(2)]

library(neuralnet)

library(nnet)

names(train) <- make.names(names(train))

train$X.30.Rango_canter<-factor(train$X.30.Rango_canter)

model<- nnet(X.30.Rango_canter~.,size=8,decay = 5e-12, maxit =
2000,rang=0.13,Hess=TRUE,
 data=train
)

names(test)<-make.names(names(test))

predicted <- predict(model,test,type="class")

table(predicted,test$X.30.Rango_canter)

...

```

```

library(dplyr)
library(readxl)
library(e1071)
library(caTools)
library(caret)

Data <- read_excel("H:\\TESIS_WORD\\[]
Merodeado_viajero\\FRRELANCER_2020\\rdait.xlsx")

g<-Data[-c(1:513),1]

Data<-Data[,-1]

standardiser <- function(x){
 (x-min(x,na.rm = TRUE))/(max(x,na.rm = TRUE)-min(x,na.rm = TRUE))
}

Data[, -c(1:2)]<-lapply(Data[, -c(1:2)], standardiser)

set.seed(4182221)

idx<-sample(1:513)

Data <- as_tibble(Data)

train <- Data[idx,-c(2)]
test <- Data[-idx,-c(2)]

library(neuralnet)
library(nnet)

names(train) <- make.names(names(train))

train$X.30.Rango_canter<-factor(train$X.30.Rango_canter)

model<- nnet(X.30.Rango_canter~.,size=6,decay = 5e-4, maxit = 2000,rang=0.73,
 data=train
)

names(test)<-make.names(names(test))

predicted <- predict(model,test,type="class")

A<-cbind(g,predicted)

View(A)

```

## **ANEXO I**

### **CÓDIGO USADO EN R PARA RAYLEIGH'S TEST Y MOORE**

```
Nota: Capítulo 15
```

```
library(CircStats)
```

```
library(circular)
```

```
library(knitr)
```

```
library(remotes)
```

```
#####
```

```
DATA Peter Stcliffe
```

```
#####
```

```
ldat1 <- c(190.2,193.5,198.5,66.6,202.1,174.6,191,200.7,342.4,221.7,59.1,341.5,181.6
)
```

```
ldat2 <- c(148.1,99.2,266.2,47.1,208.8,149.8,170.7,257.3,348.1,312.1,44.4,347.9,61.2
)
```

```
#####
```

```
 #(ldat1) Are the angles (in degrees) from anchor point to attacks
```

```
 #(ldat2) Are the angles (in degrees) from center minimum distance to attacks
```

```
#####
```

```
Rayleigh's R_p (uniform)
```

```
#####
```

```
r.test(ldat1, degree = TRUE)
```

```
r.test(ldat2, degree = TRUE)
```

```
#####
```

```
Moore's test for a common distribution for paired samples
```

```
#####
```

```

cdat1d <- circular(lдат1, units="degrees", zero=pi/2, rotation="clock")
cdat2d <- circular(lдат2, units="degrees", zero=pi/2, rotation="clock")
plot(cdat1d, pch=16, cex=1.5, shrink=0.9, stack=T, sep=0.037, bins=360)
ticks.circular(circular(seq(0,(15/8)*pi,pi/8)), tcl=0.075)
points(cdat2d, pch=16, cex=1.5, stack=T, sep=0.037, bins=360, col="red")

```

```

lдат1 <- lдат1*2*pi/360 ; lдат2 <- lдат2*2*pi/360

```

```

MooreRStats <- function(lдат1, lдат2) {
 x <- cos(lдат1)-cos(lдат2); y <- sin(lдат1)-sin(lдат2)
 r <- sqrt((x*x)+(y*y)) ; Ranks <- rank(r)
 cosphi <- x/r; sinphi <- y/r
 return(list(cosphi, sinphi, Ranks))
}

```

```

RoostingStats <- MooreRStats(lдат1, lдат2)
cosphi <- RoostingStats[[1]] ; sinphi <- RoostingStats[[2]] ; Ranks <-
RoostingStats[[3]]

```

```

MooreRTestStat <- function(cosphi, sinphi, Ranks){
 n <- length(cosphi)
 RbarC <- (1/n)*sum(Ranks*cosphi); RbarS <- (1/n)*sum(Ranks*sinphi)
 Rval <- sqrt(((RbarC*RbarC)+(RbarS*RbarS))/n) ; return(Rval)
}

```

```

MooreRTestRand <- function(cosphi, sinphi, Ranks, NR) {
 RObs <- MooreRTestStat(cosphi, sinphi, Ranks) ; nxtrm <- 1
 n <- length(cosphi)
 for (r in 1:NR) {
 cosphirand <- 0 ; sinphirand <- 0

```

```

for (j in 1:n) {
 if (runif(1) < 0.5) {
 cosphirand[j] <- cosphi[j] ; sinphirand[j] <- sinphi[j] }
 else {
 cosphirand[j] <- -cosphi[j] ; sinphirand[j] <- -sinphi[j] } }
RRand <- MooreRTestStat(cosphirand, sinphirand, Ranks)
if (RRand >= RObs) { nxtrm <- nxtrm+1 }
}
pval <- nxtrm/(NR+1) ; return(c(RObs, pval))
}

NR <- 9999 ; MooreRTestRand(cosphi, sinphi, Ranks, NR)

#####
p adjust Benjamini-Hochberg p(uniform) Rayleigh's p Moores Test (p)
#####

pvals = c()
BONF = p.adjust(pvals, "bonferroni")
BH = p.adjust(pvals, "BH")
res = cbind (pvals, BH = round (BH, 3), BONF = round (BONF, 3))

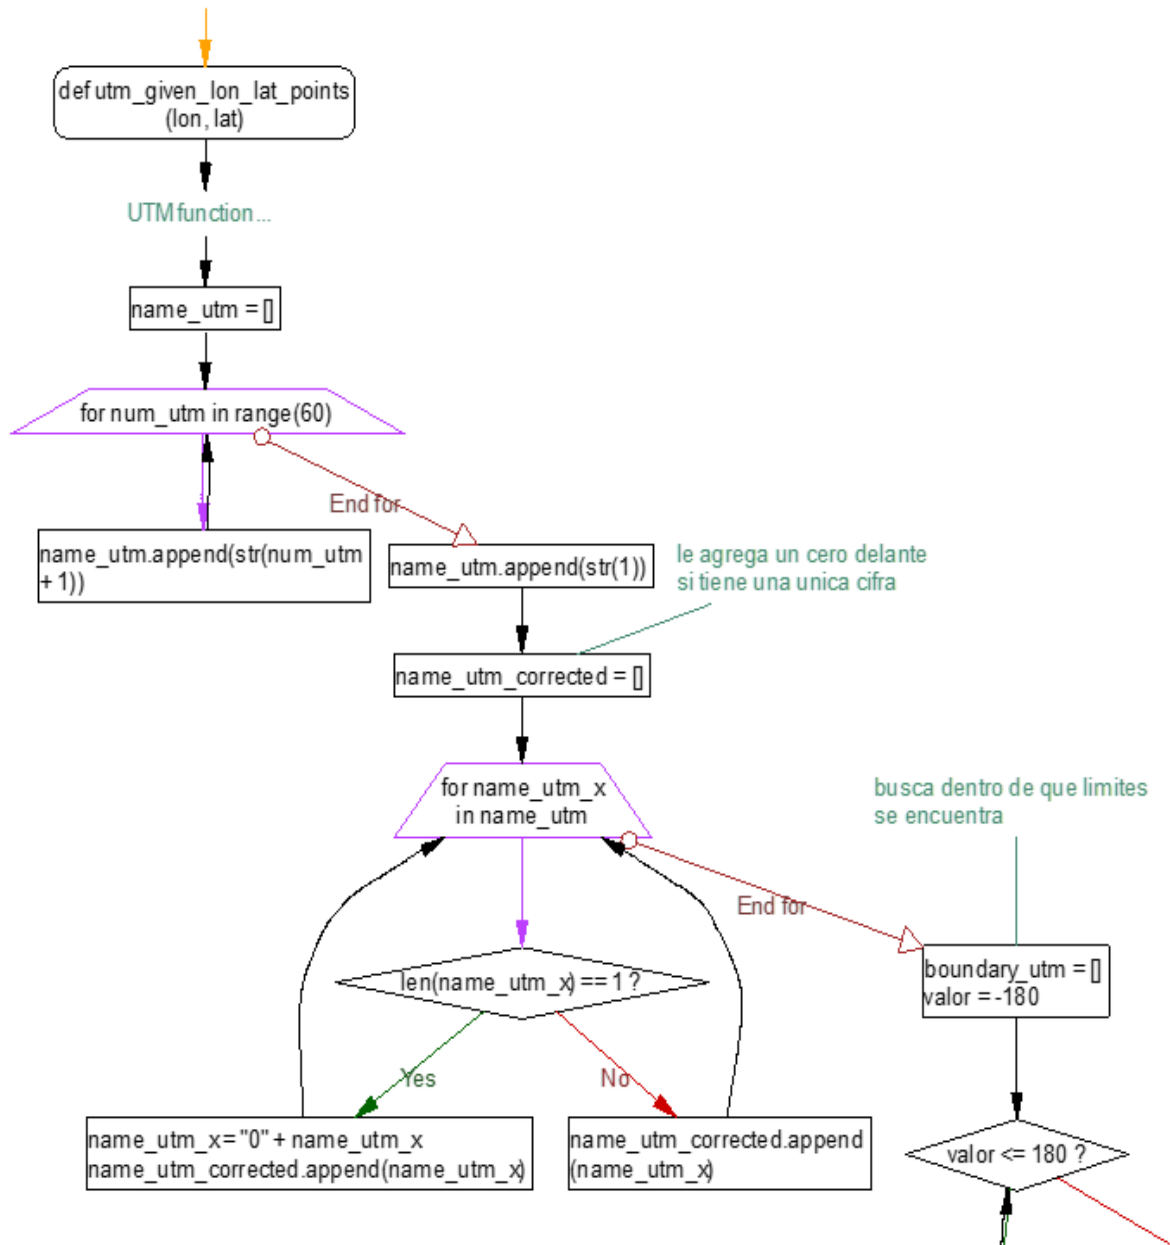
#####

```

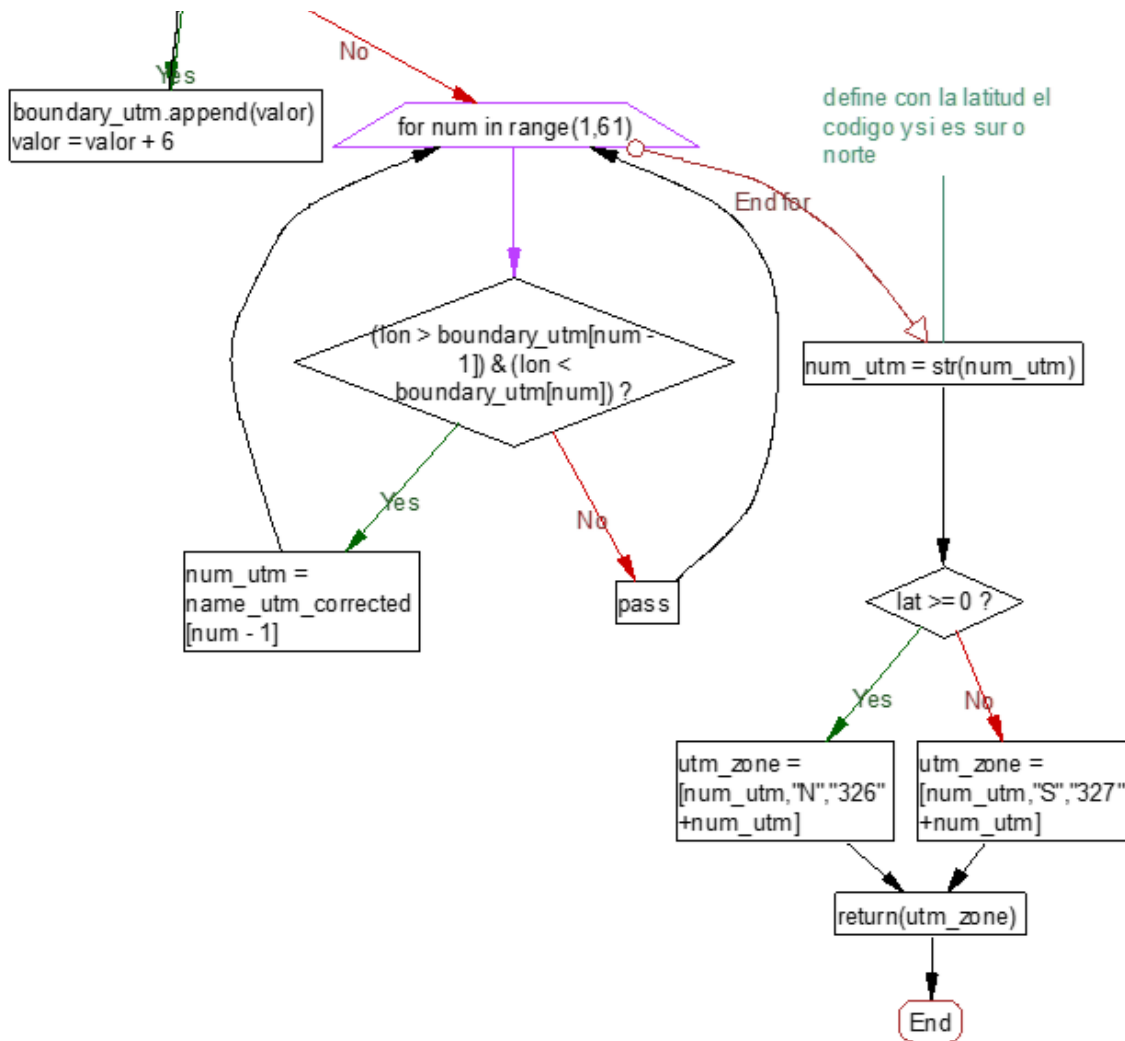
## **ANEXO J**

### **ESTRUCTURA DEL ALGORITMO EN DIAGRAMAS DE FLUJO**

### 7.2.3. Transformación de coordenadas geográficas a proyectadas.







**Figura 7.4** Diagrama de flujo. Transformaciones coordenadas geográficas a proyectadas

## 7.2.4 Comprobación Merodeador / Viajero

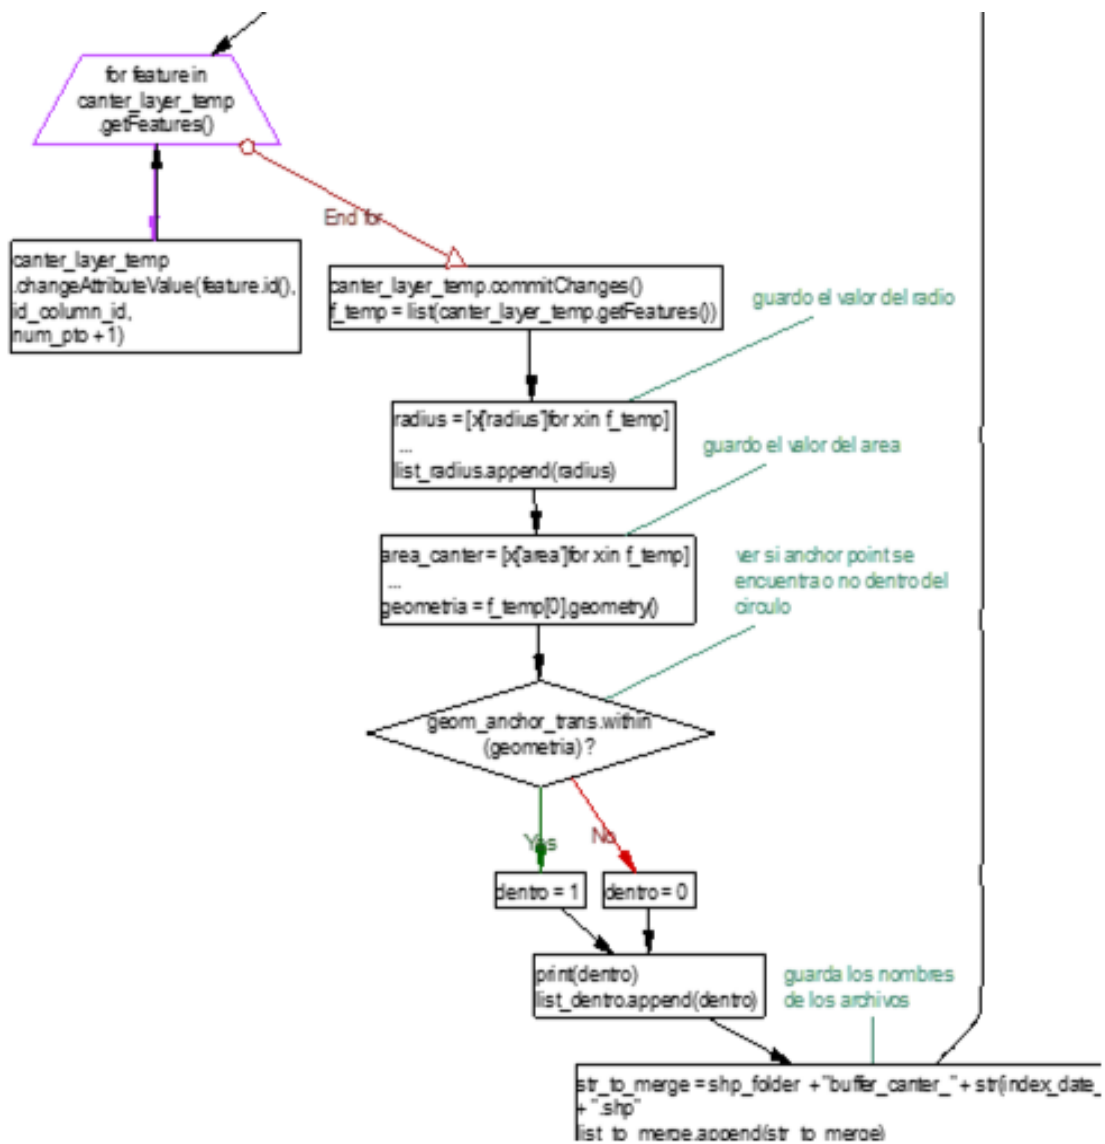
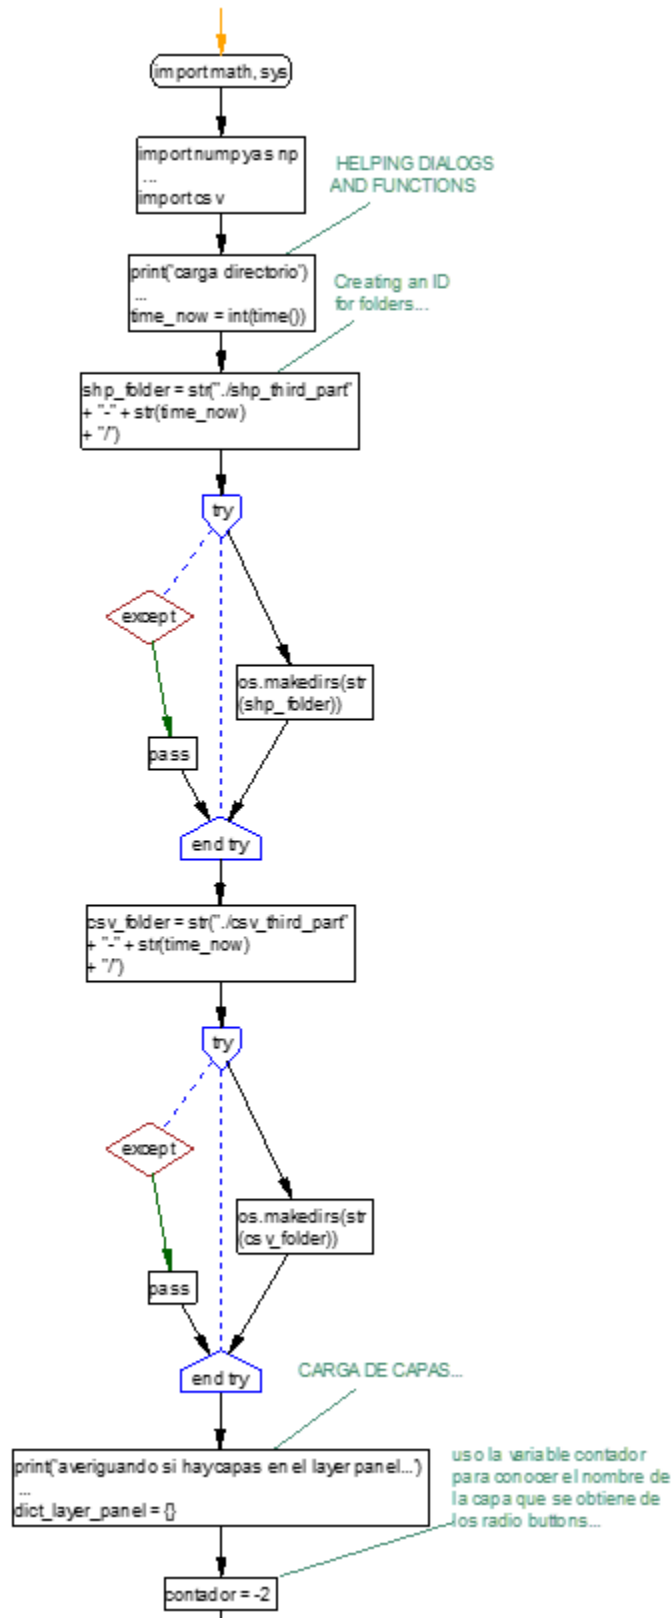
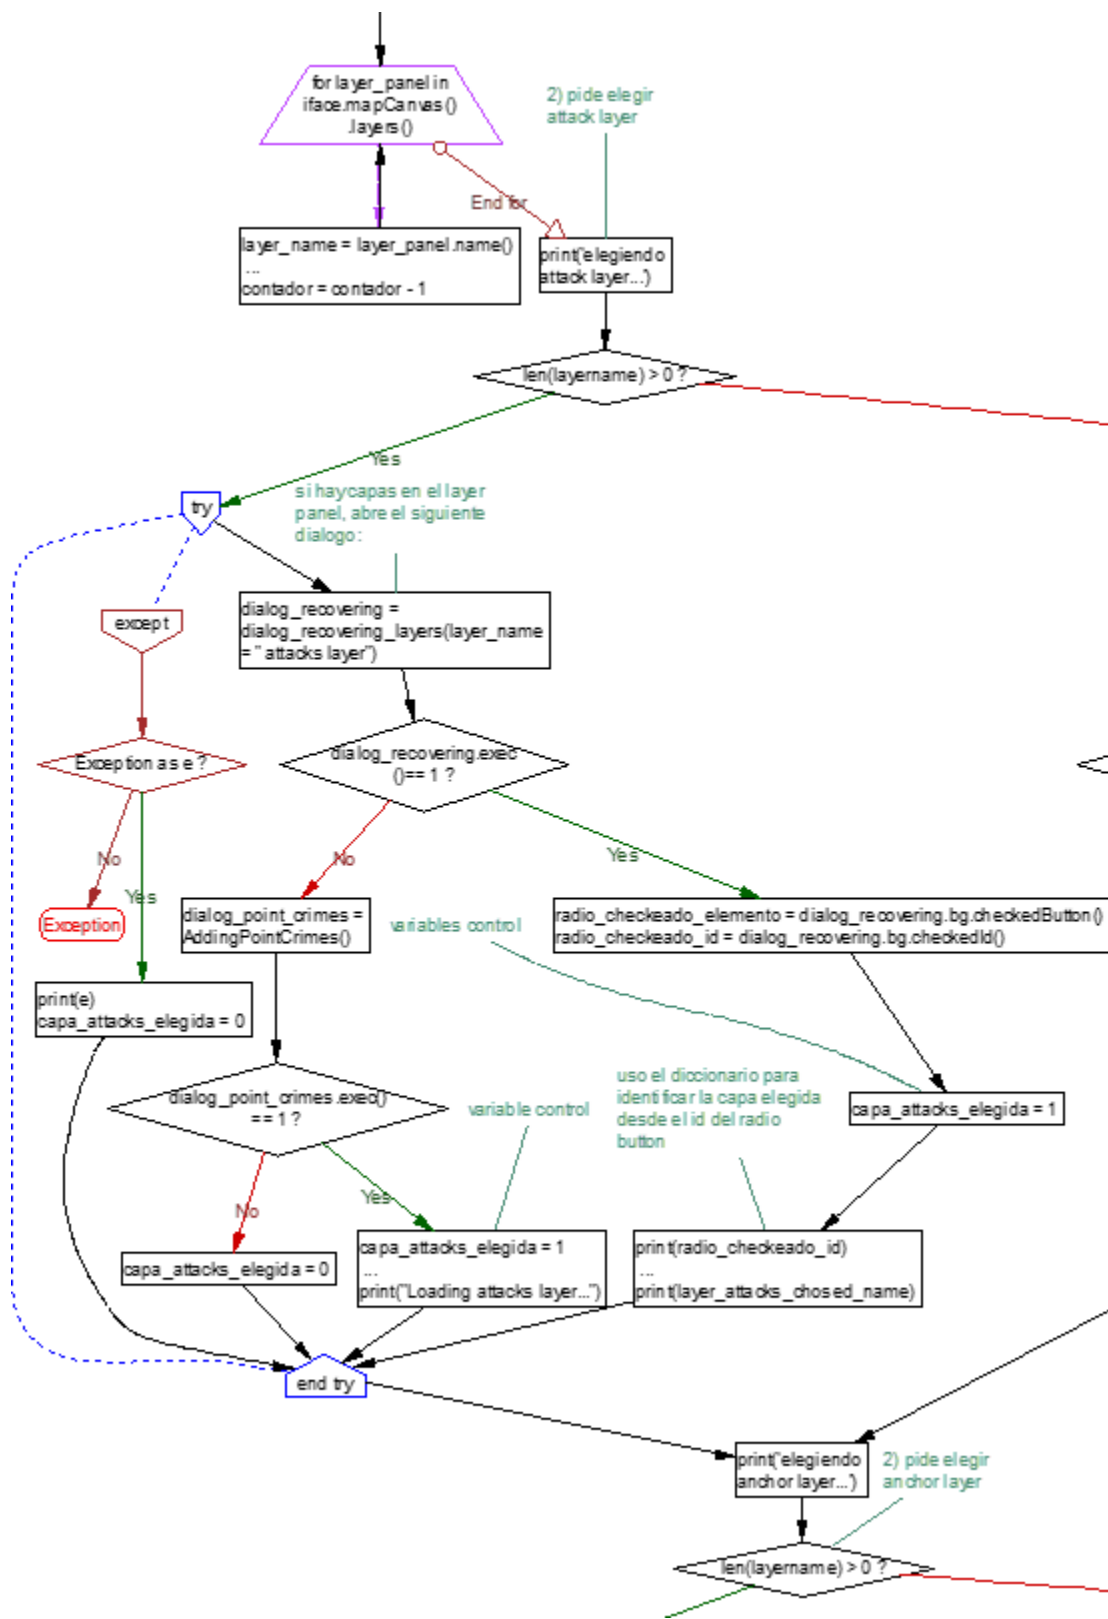
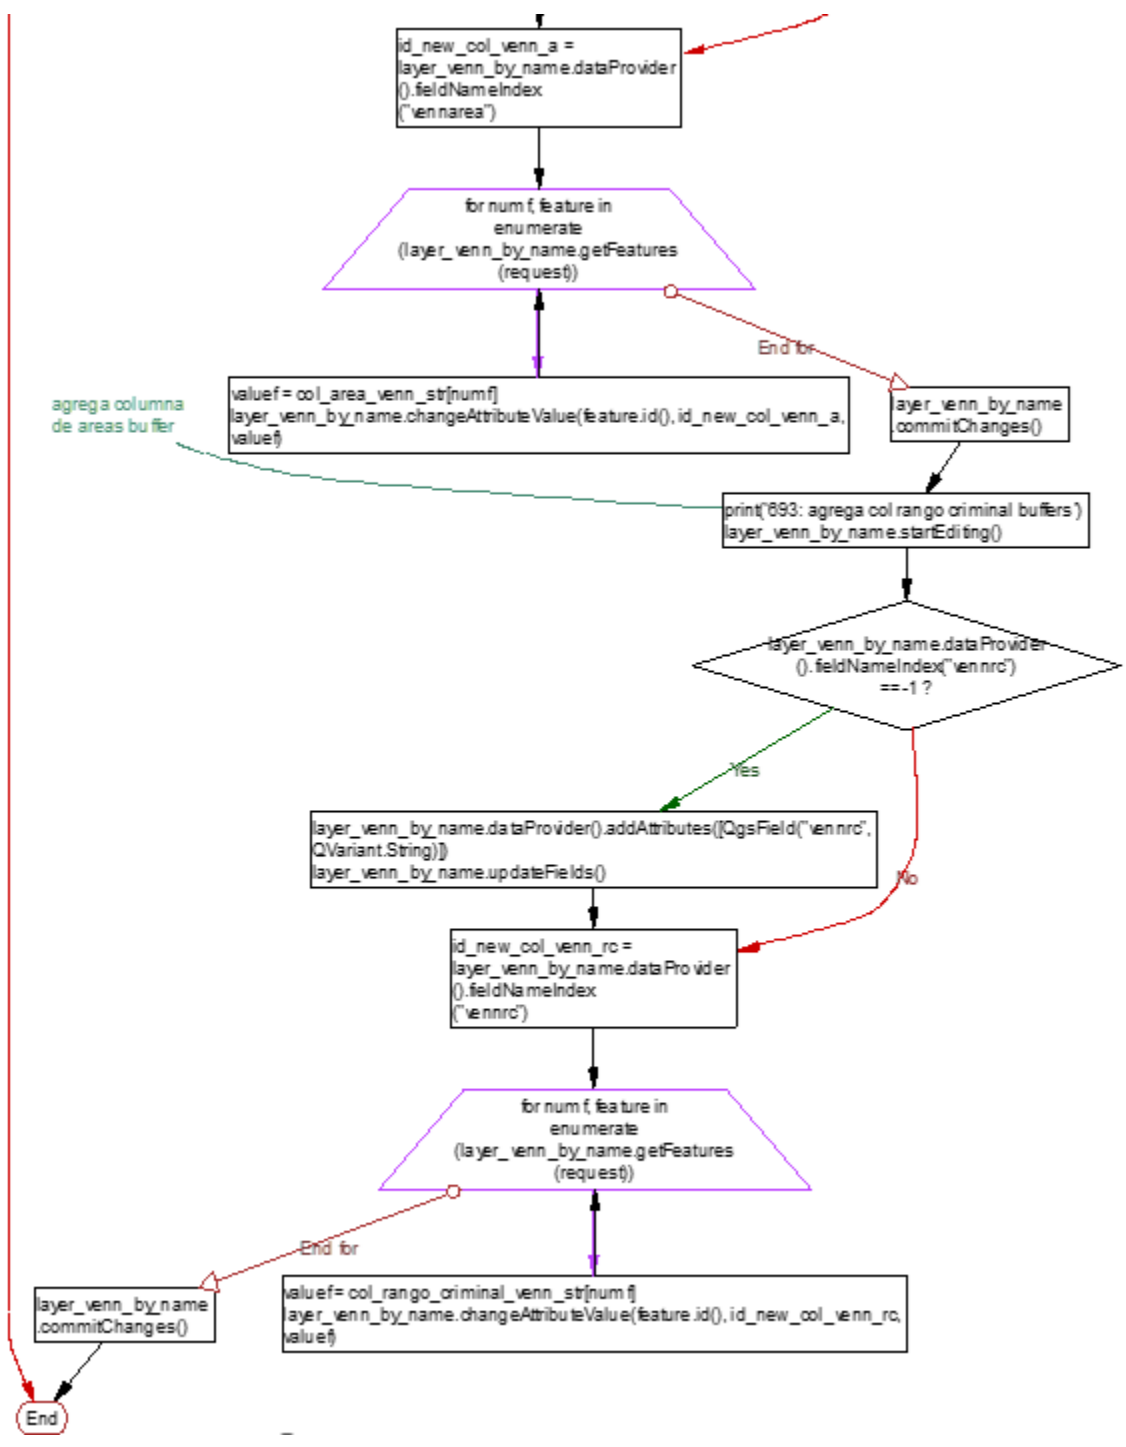


Figura 7-6 Diagrama de Flujos. Comprobación merodeador o viajero.

## 7.2.5 Estrategia distribución espacial (centro mínima distancia, centroide)







agrega columna de areas bu ffer

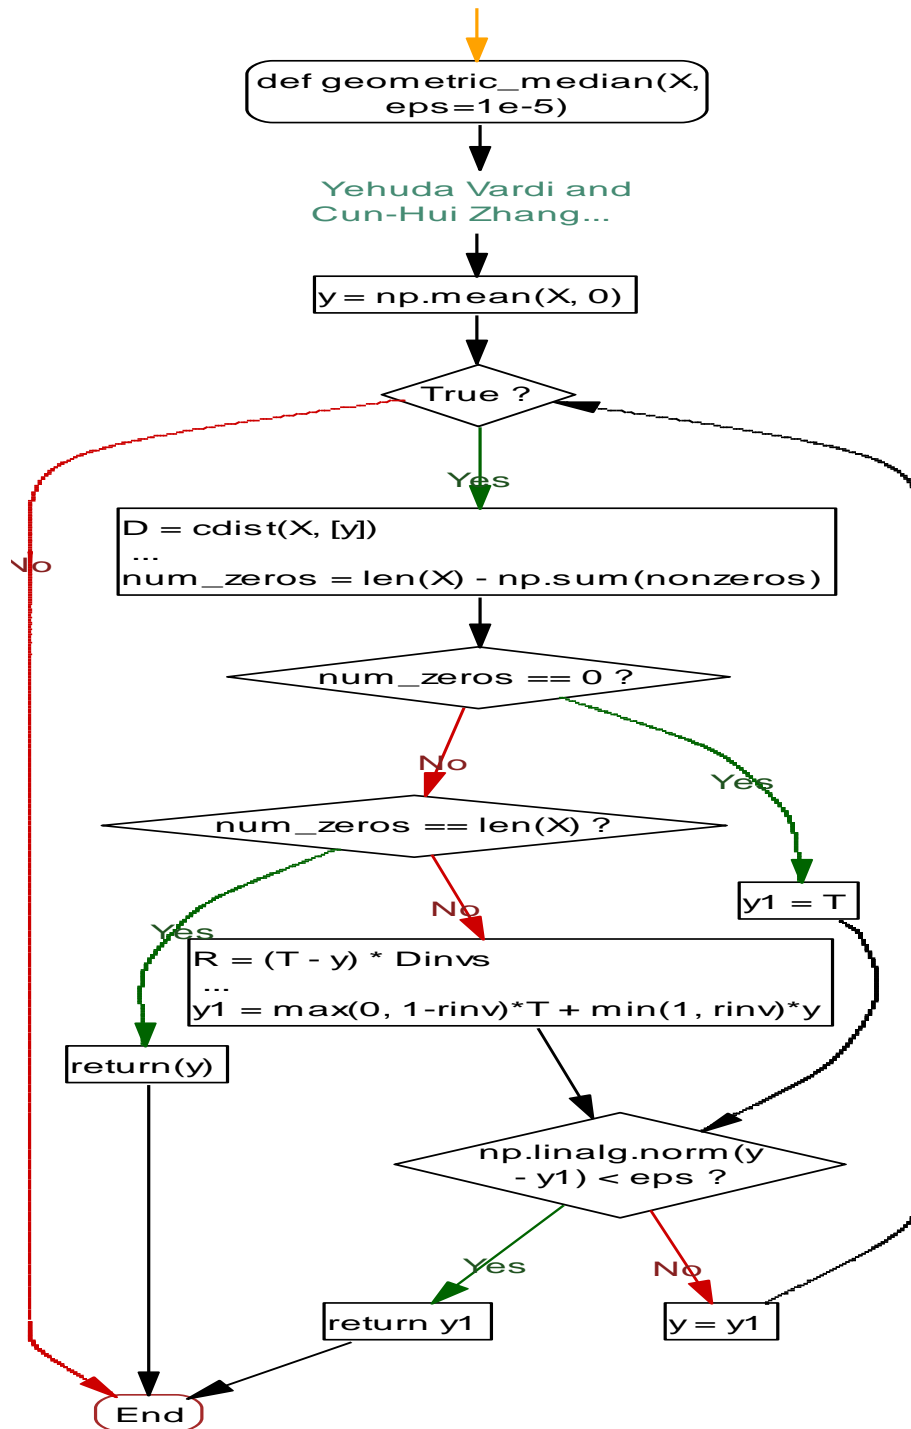
End for

Yes

No

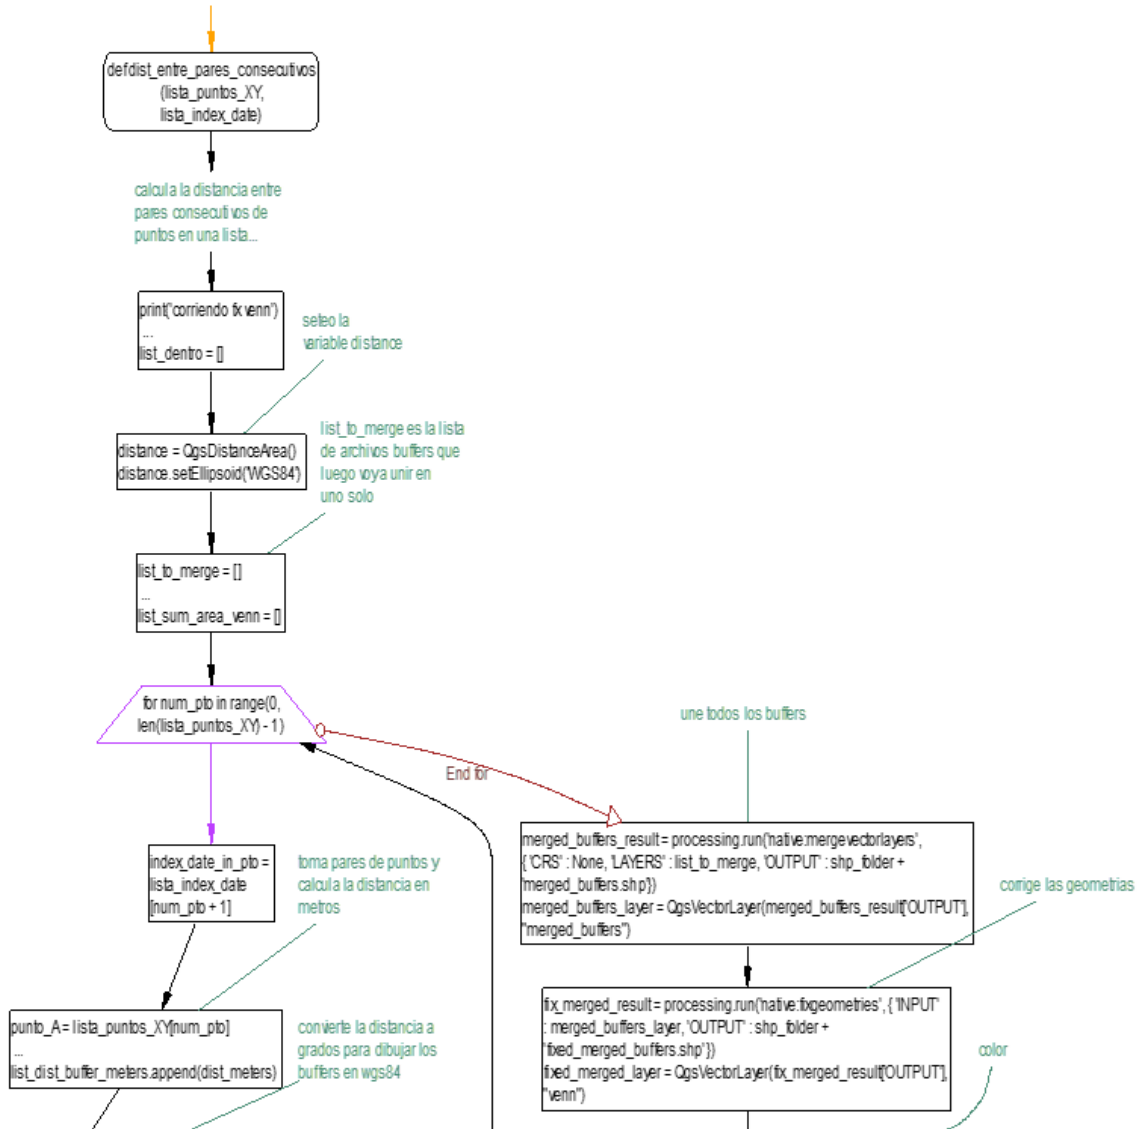
End for

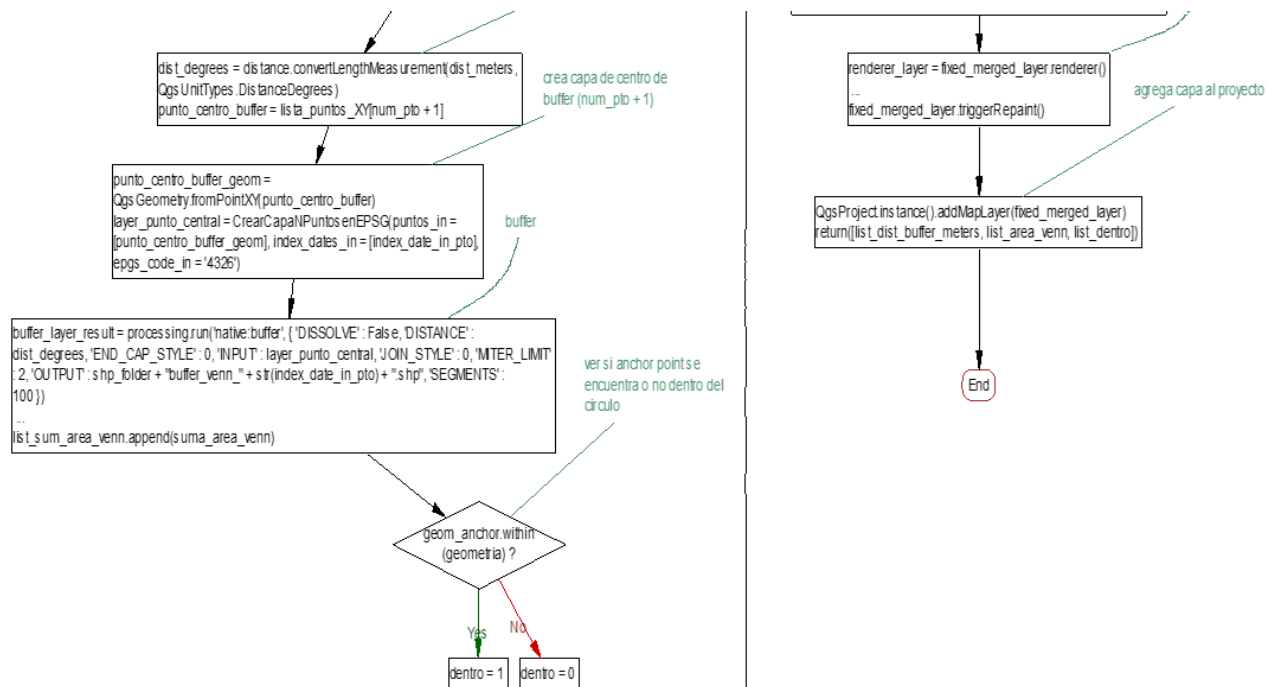
End



**Figura 7-9** Diagrama de flujos. Implementación en QGIS del algoritmo de Yehuda Vardi y Cun-Hui Zhang para el centro de mínima distancia.

## 7.2.6 Estrategia de distribución de dispersión (Diagrama de Venn)

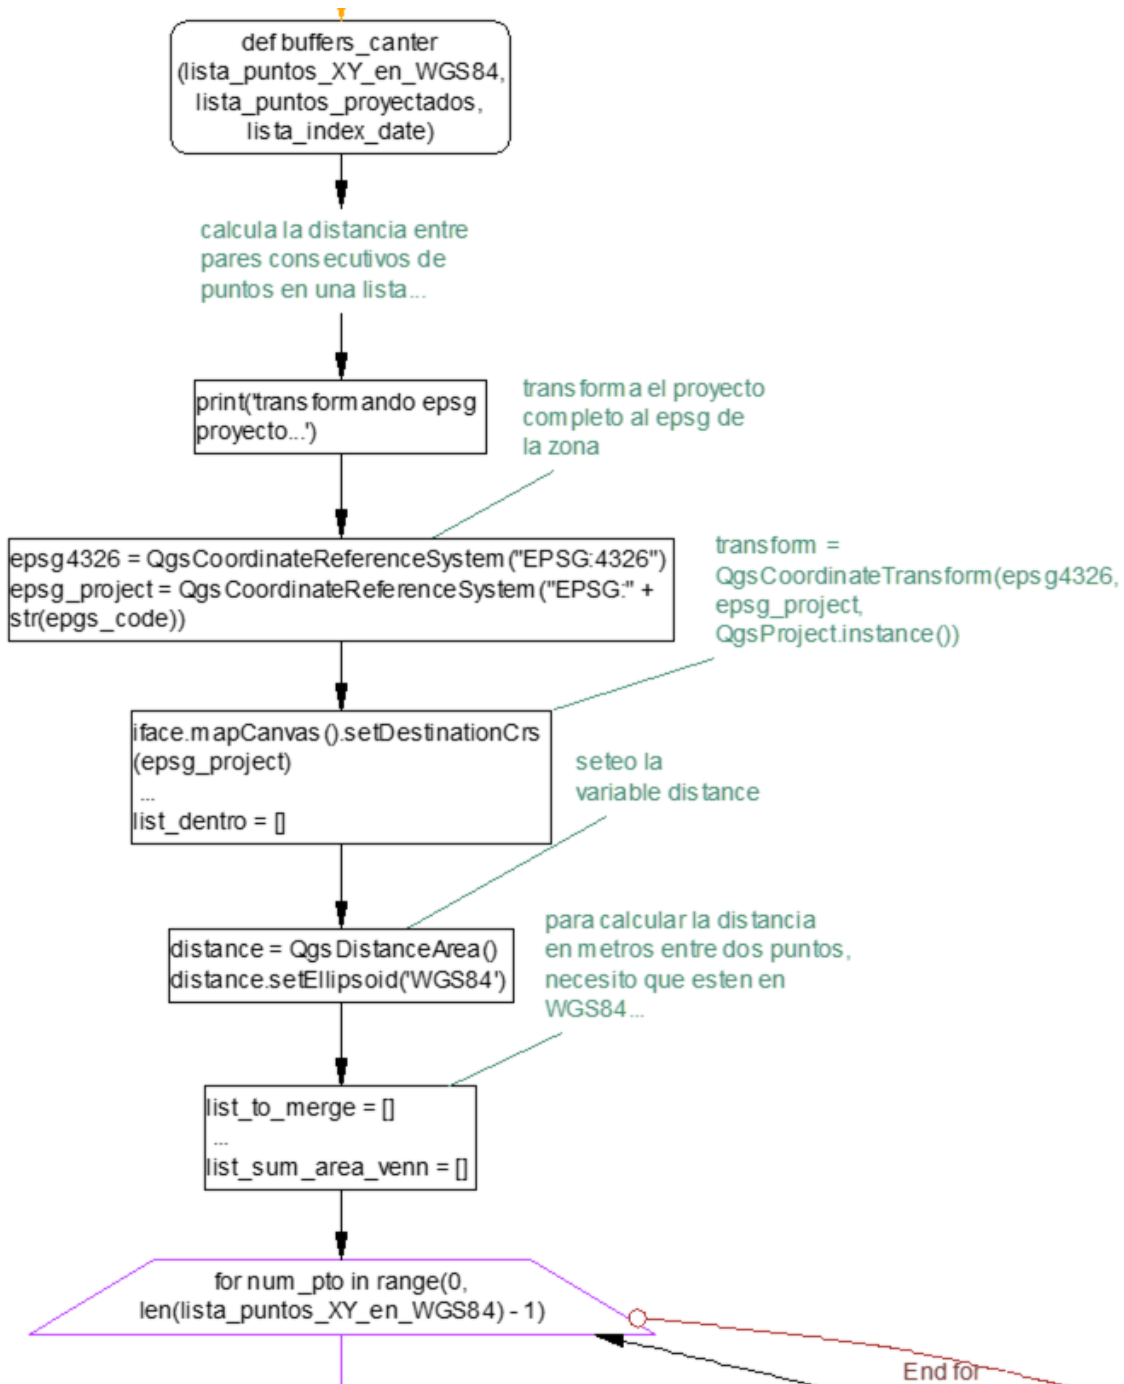




**Figura 7-11** Diagrama de flujos. Estrategia de distribución de dispersión



## 7.2.7 Estrategia de distribución de dispersión (Círculo de Canter)



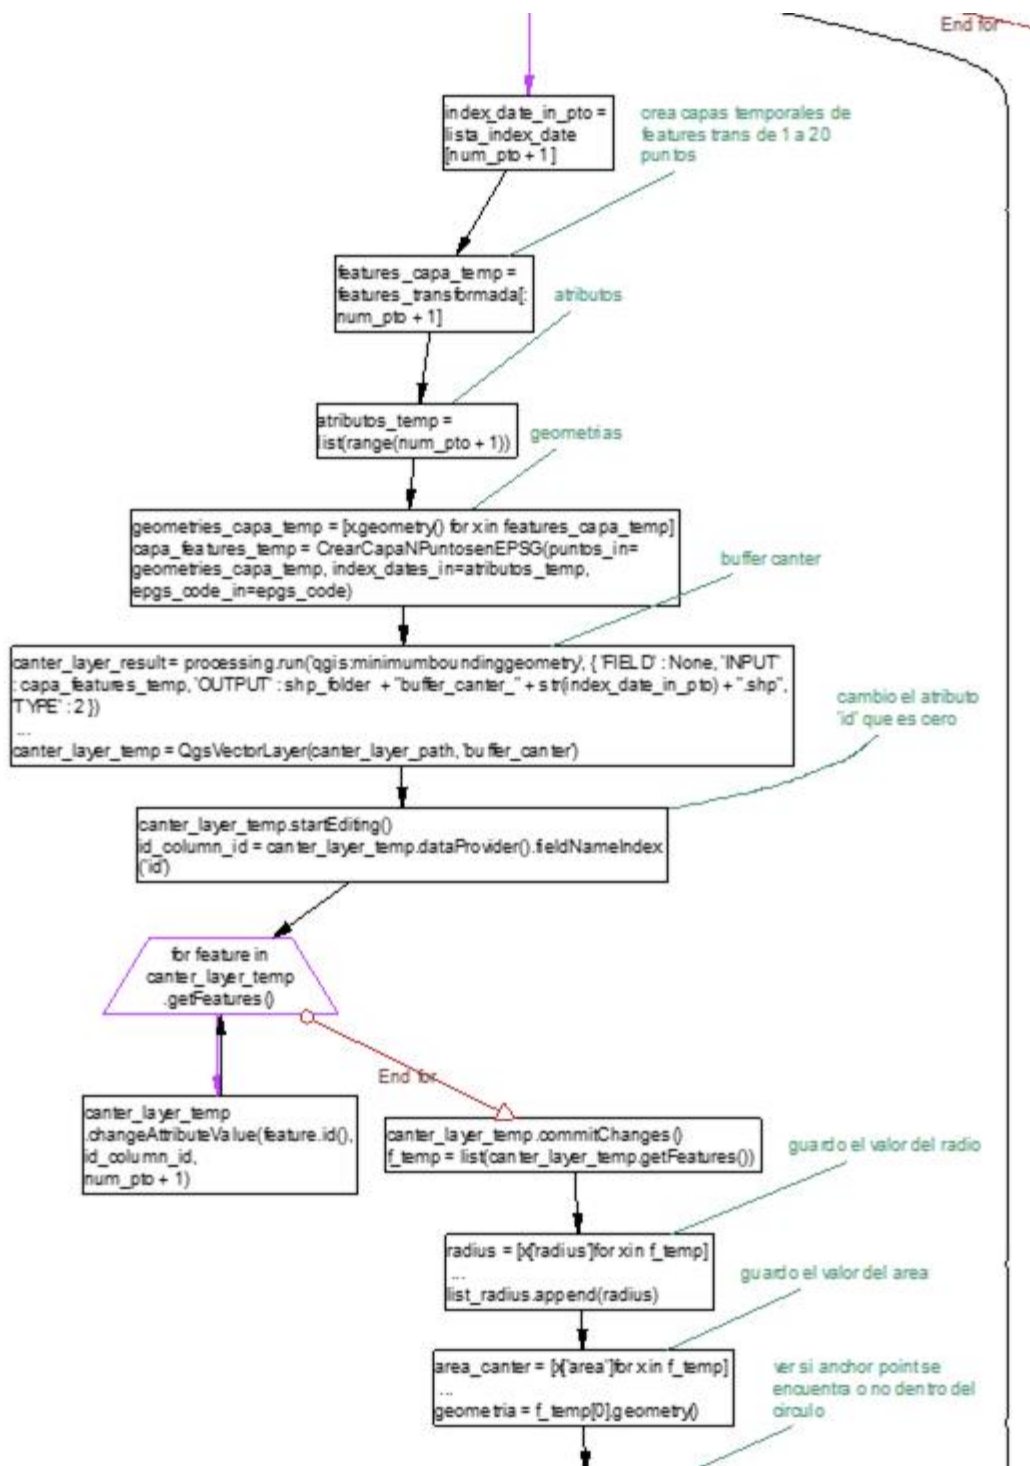
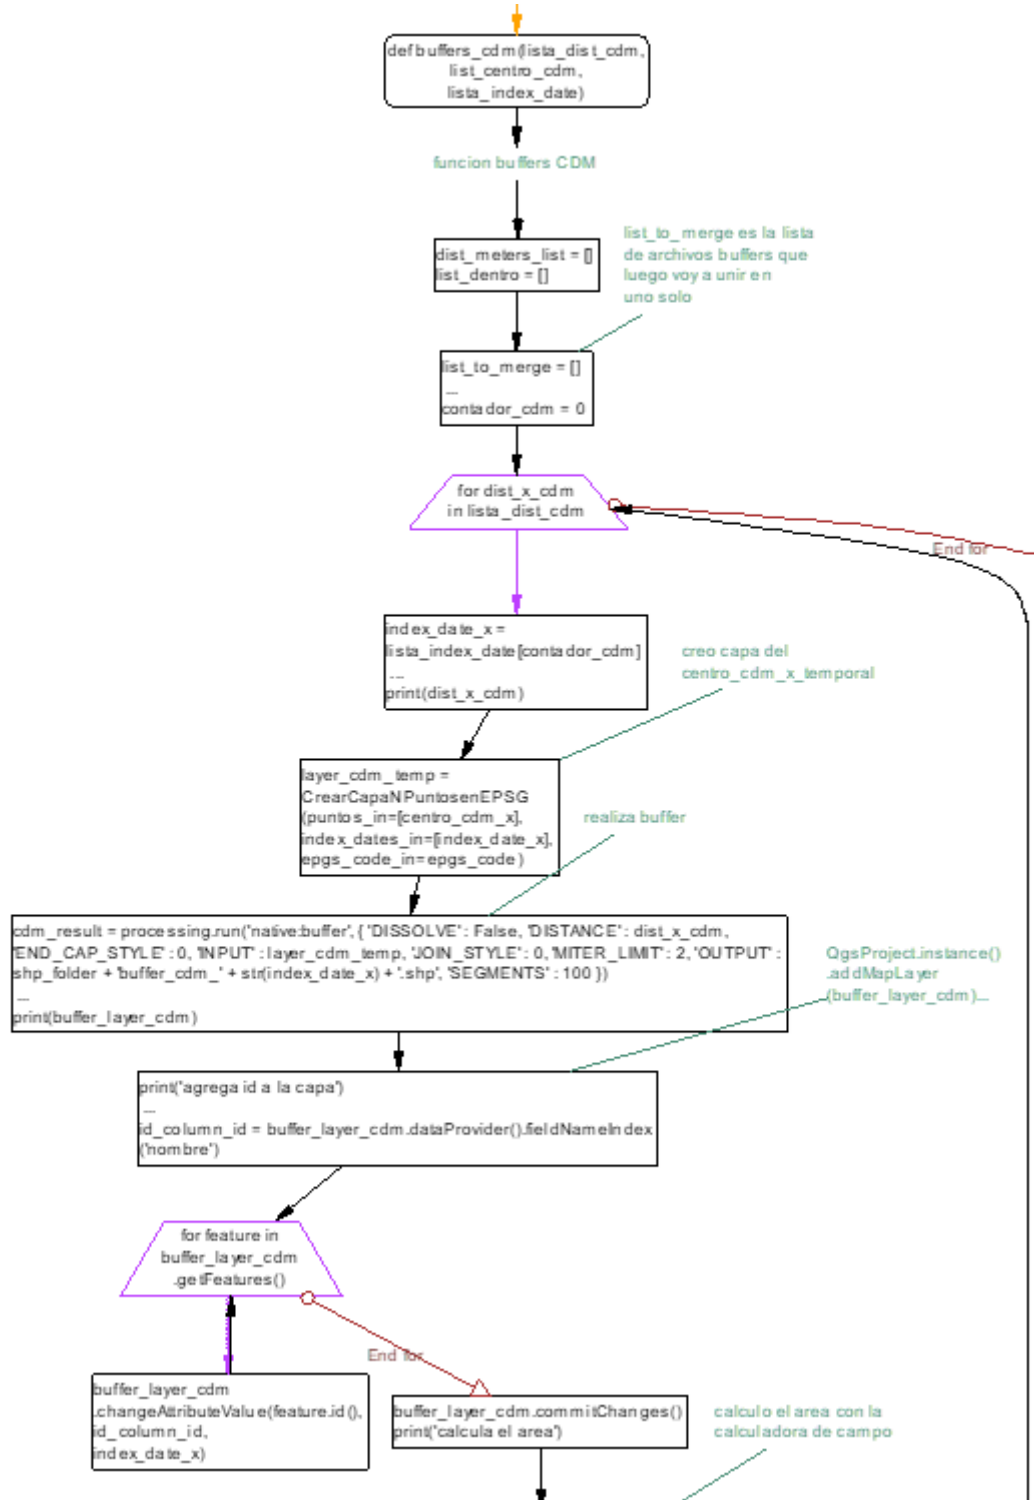
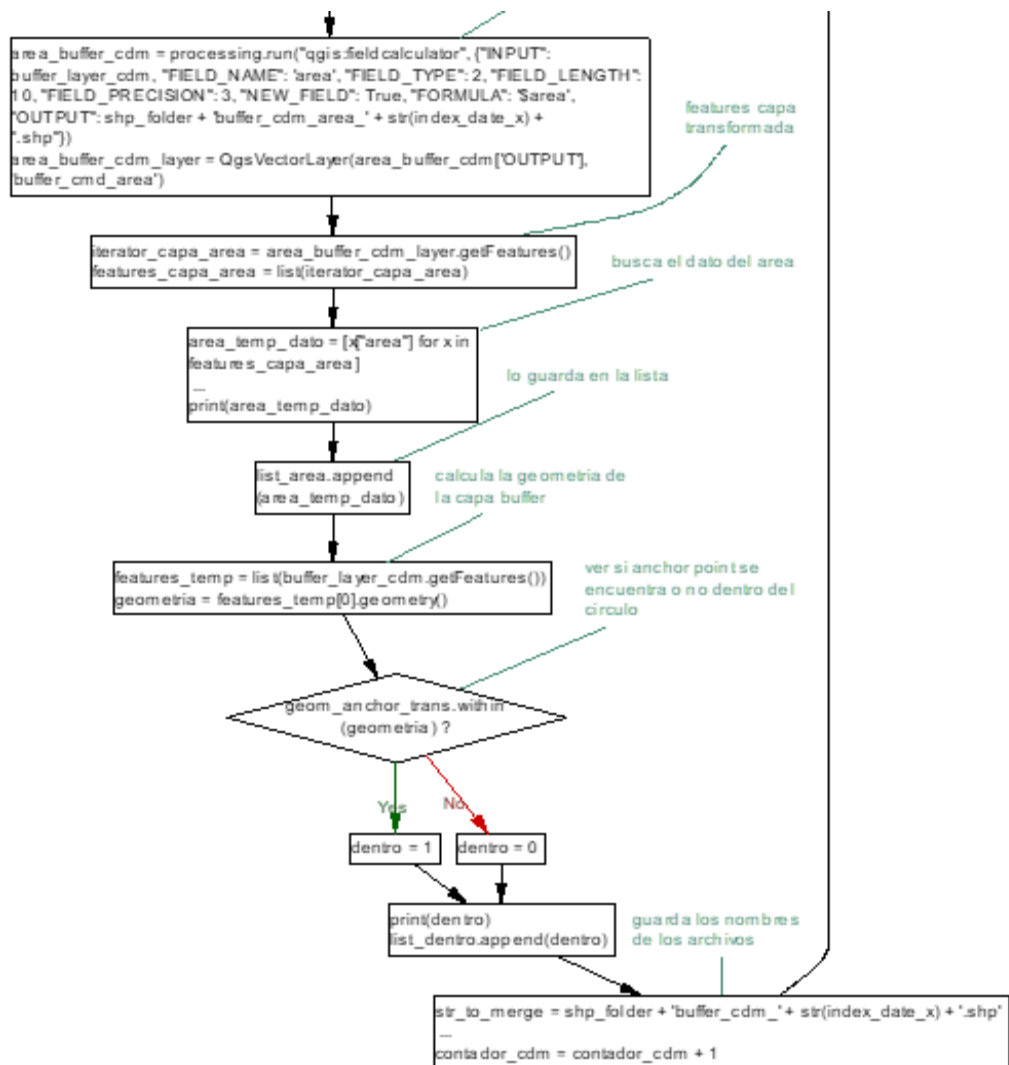


Figura 7-13 Diagrama de flujos. Estrategia de distribución de dispersión (Círculo de Canter).

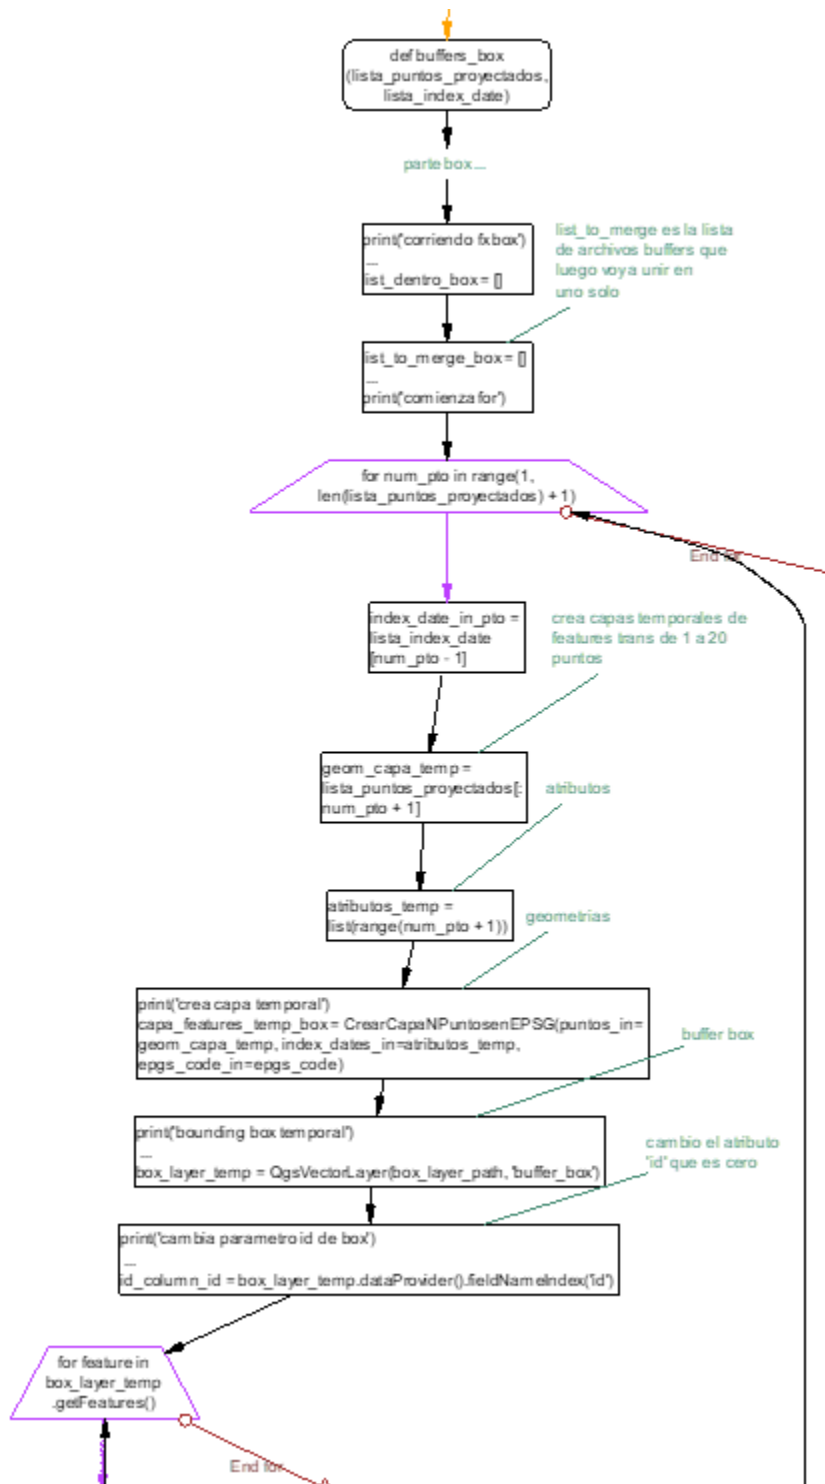
## 7.2.8 Estrategia de distribución de dispersión (Círculo centro mínima distancia)

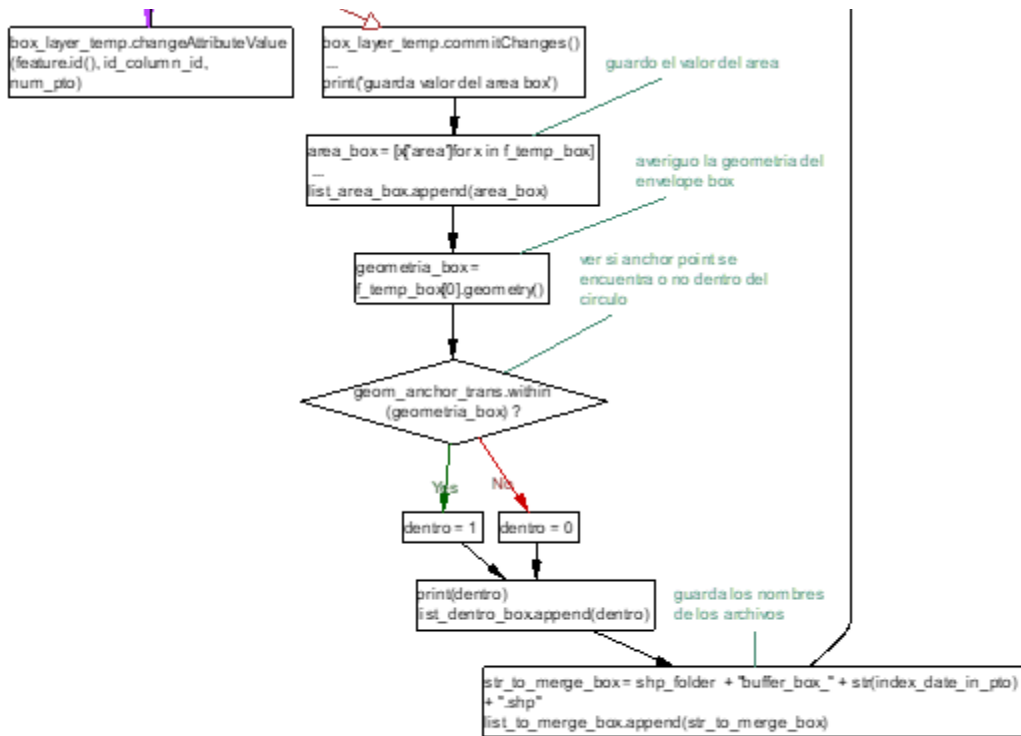




**Figura 7-15** Diagrama de flujos. Estrategia de distribución de dispersión (Priorización del Centroides Aritmético).

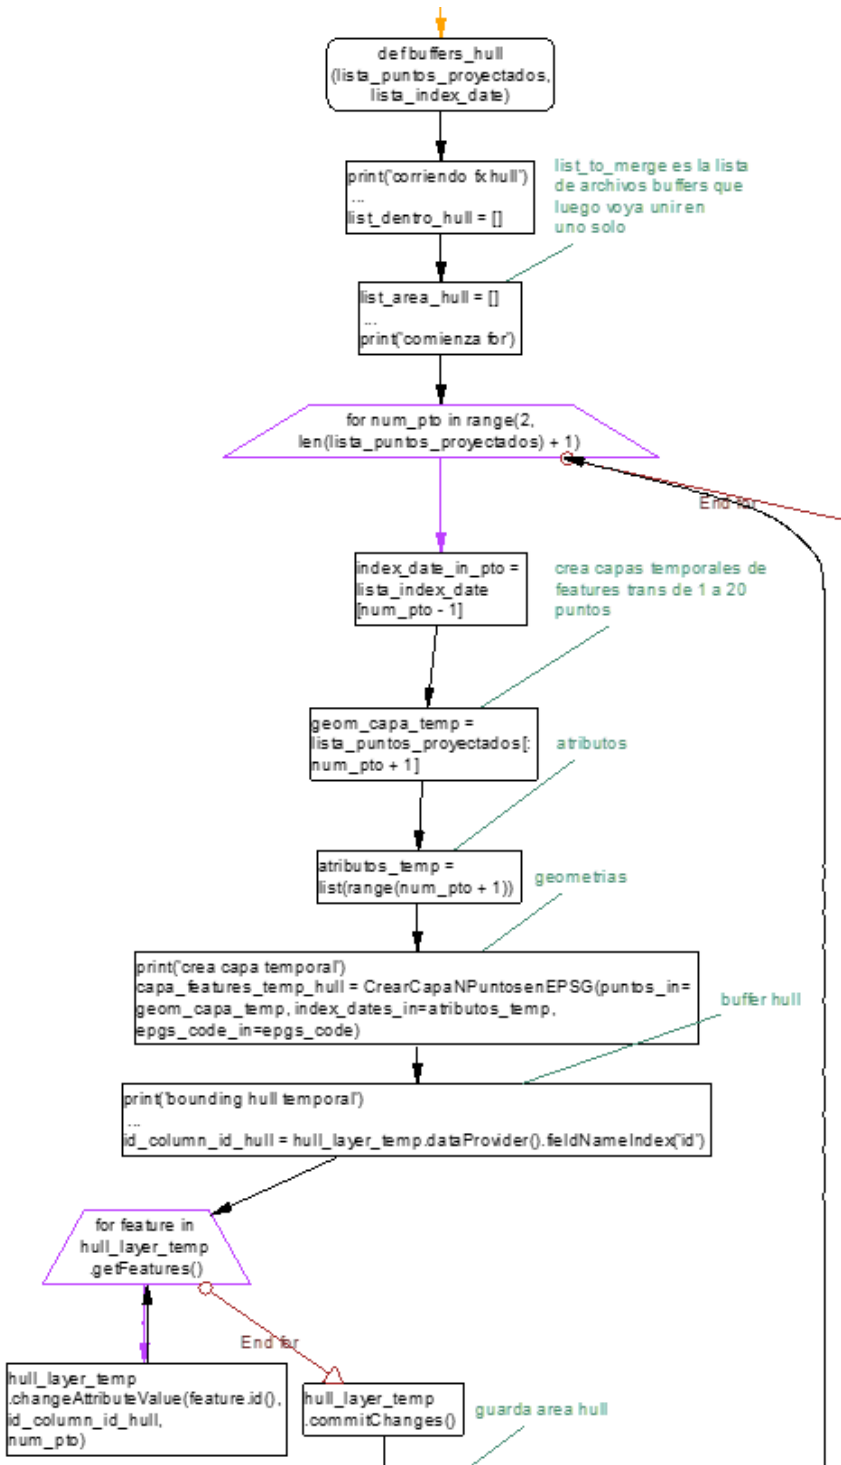
## 7.2.9 Estrategia de distribución de dispersión (Rectángulo área mínima limitación)

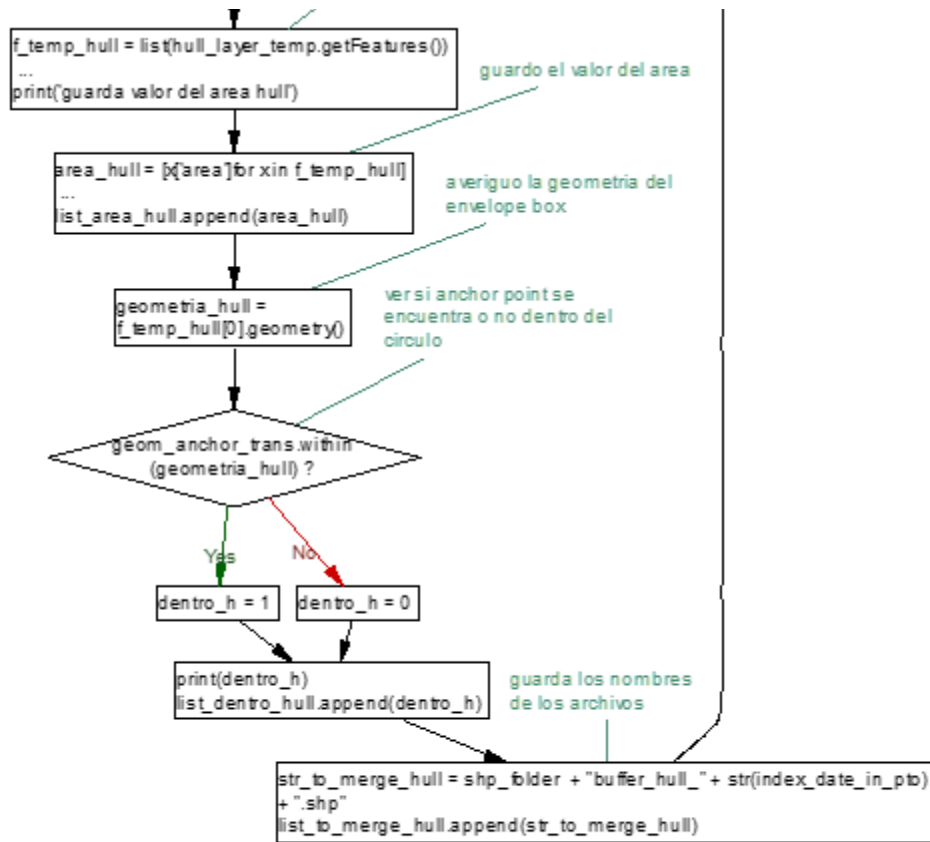




**Figura 7-17** Diagrama de flujos. Estrategia de distribución de dispersión (Rectángulo mínima delimitación).

## 7.2.9a Estrategia de distribución de dispersión (Envolvente convexa)

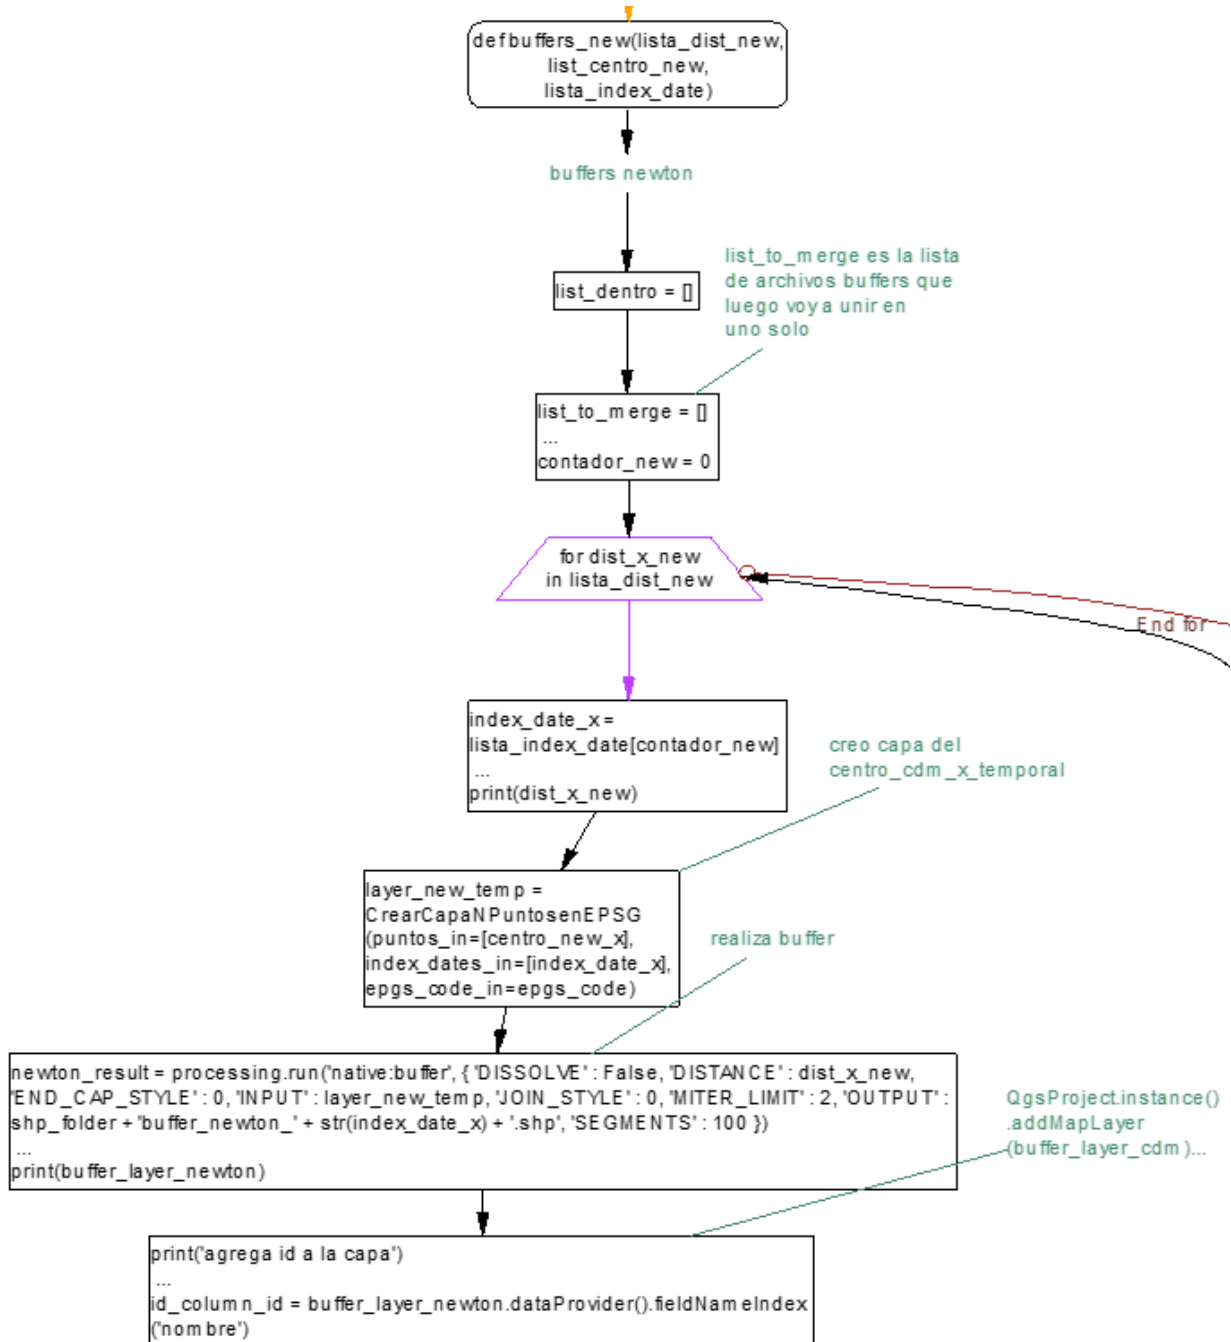




**Figura 7-19** Diagrama de flujos. Estrategia de distribución de dispersión (Envolvente convexa.)



## 7.2.9b Estrategia de distribución de dispersión (Newton-Swoope)



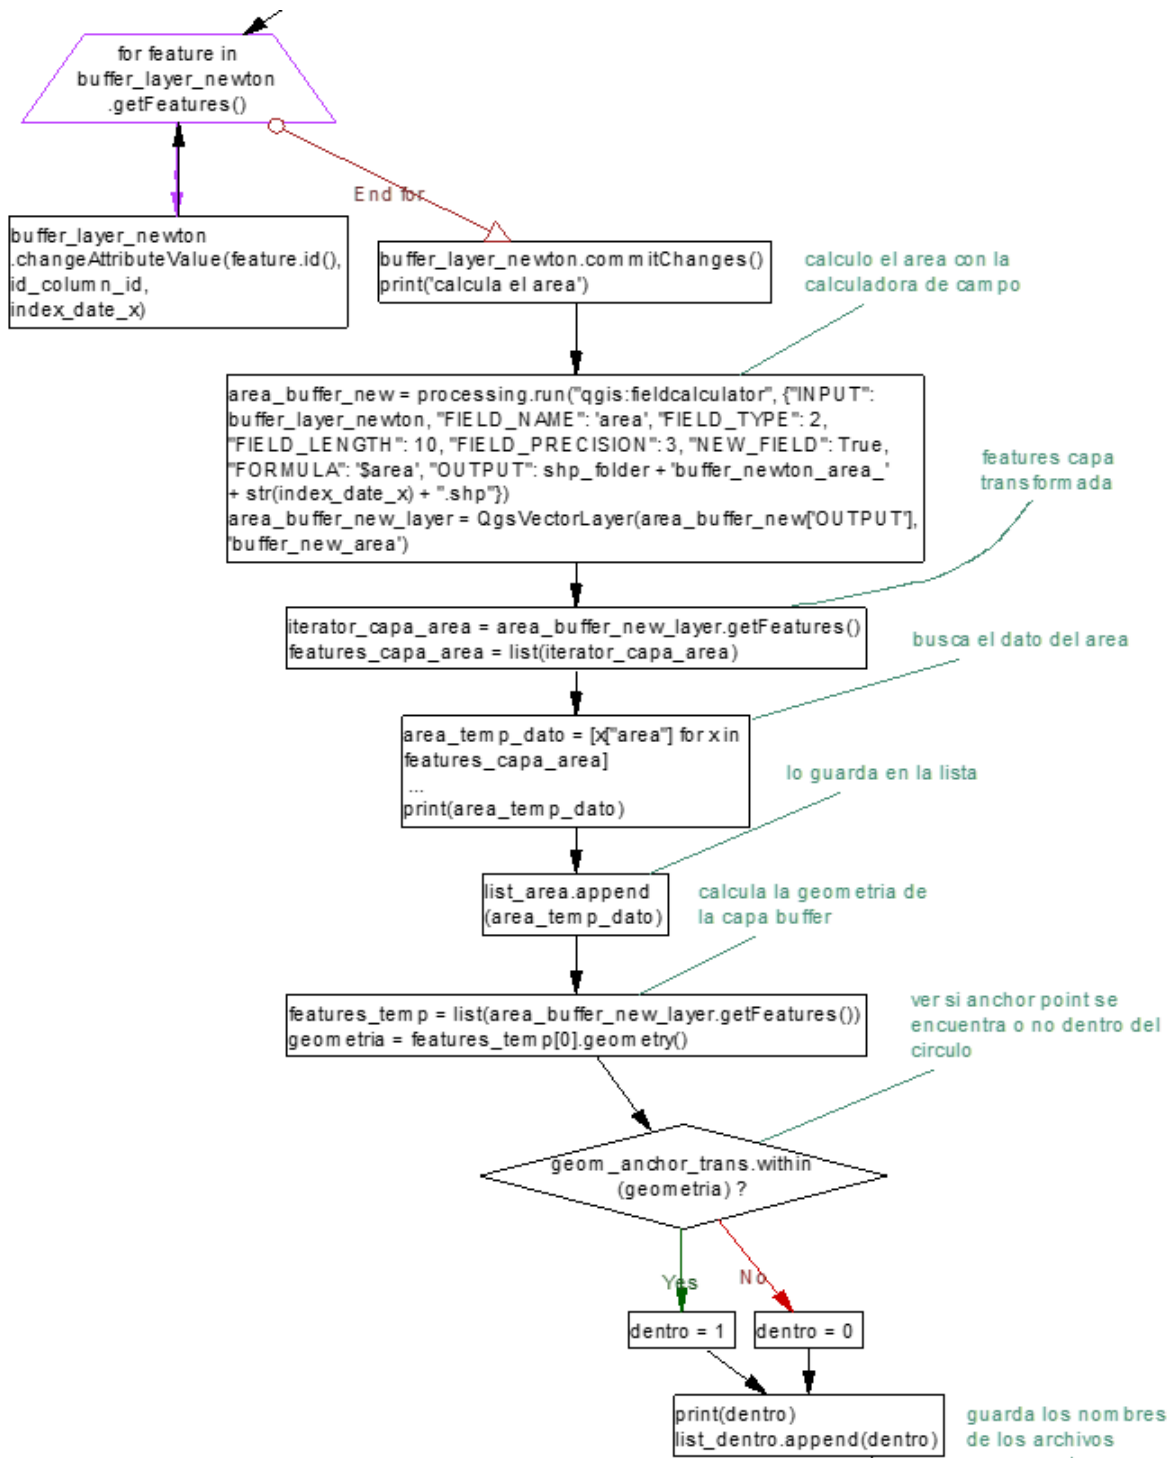
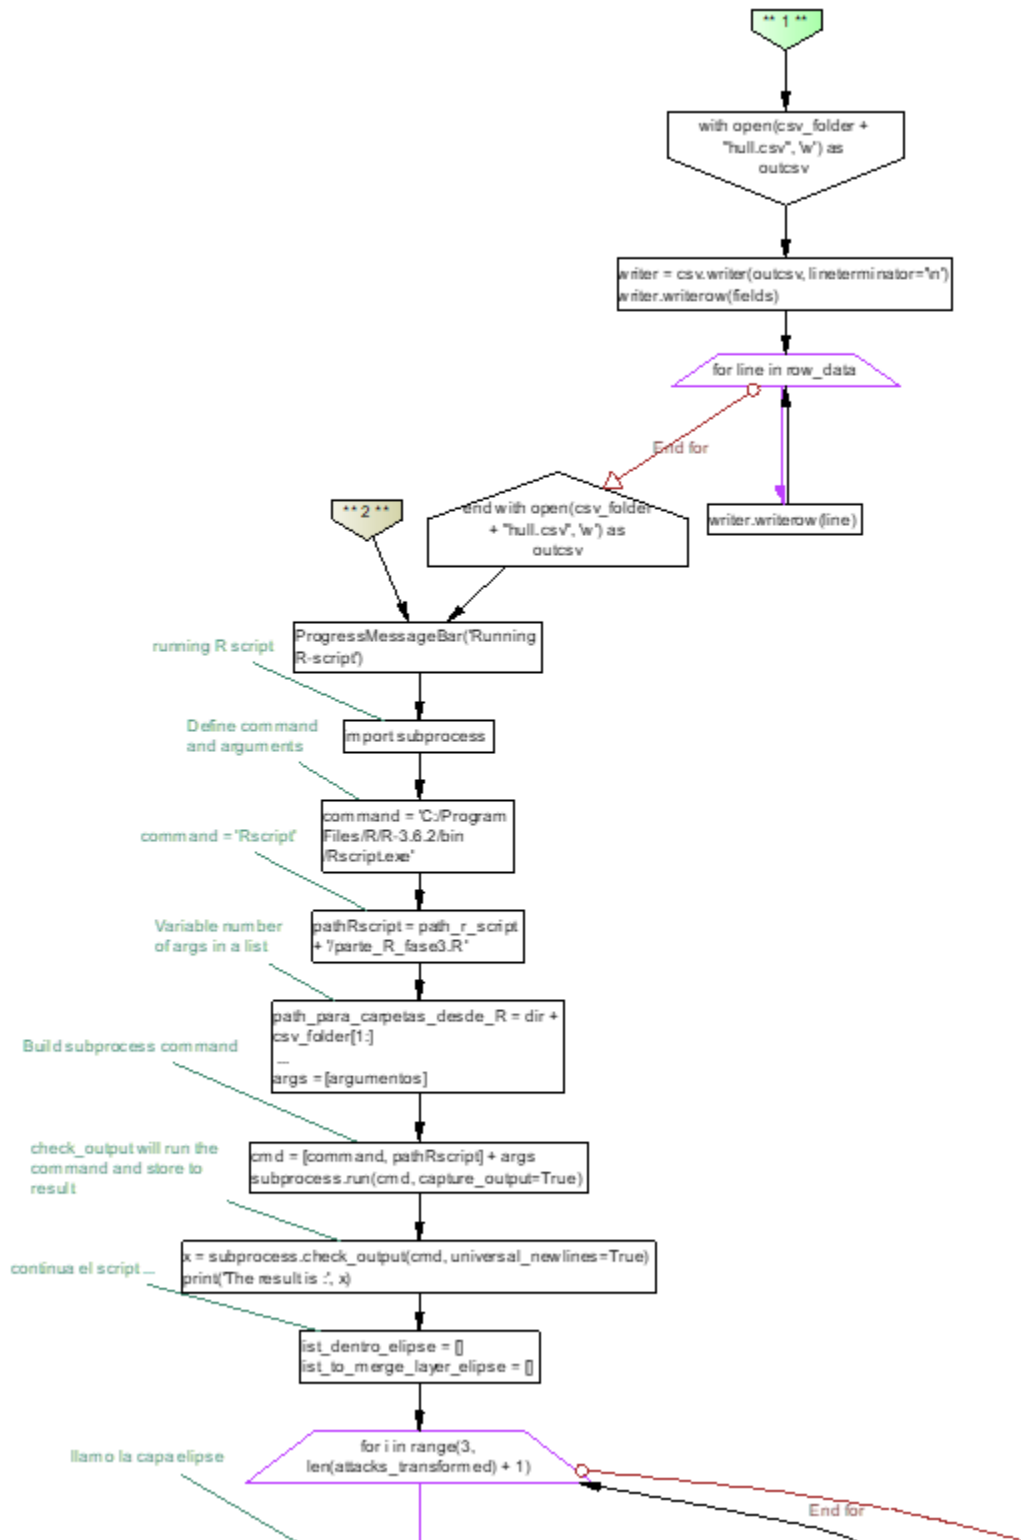


Figura 7-21 Diagrama de flujos. Estrategia de distribución (Newton-Swoope)

## 7.2.9c Estrategia de distribución de dispersión (Elipse)



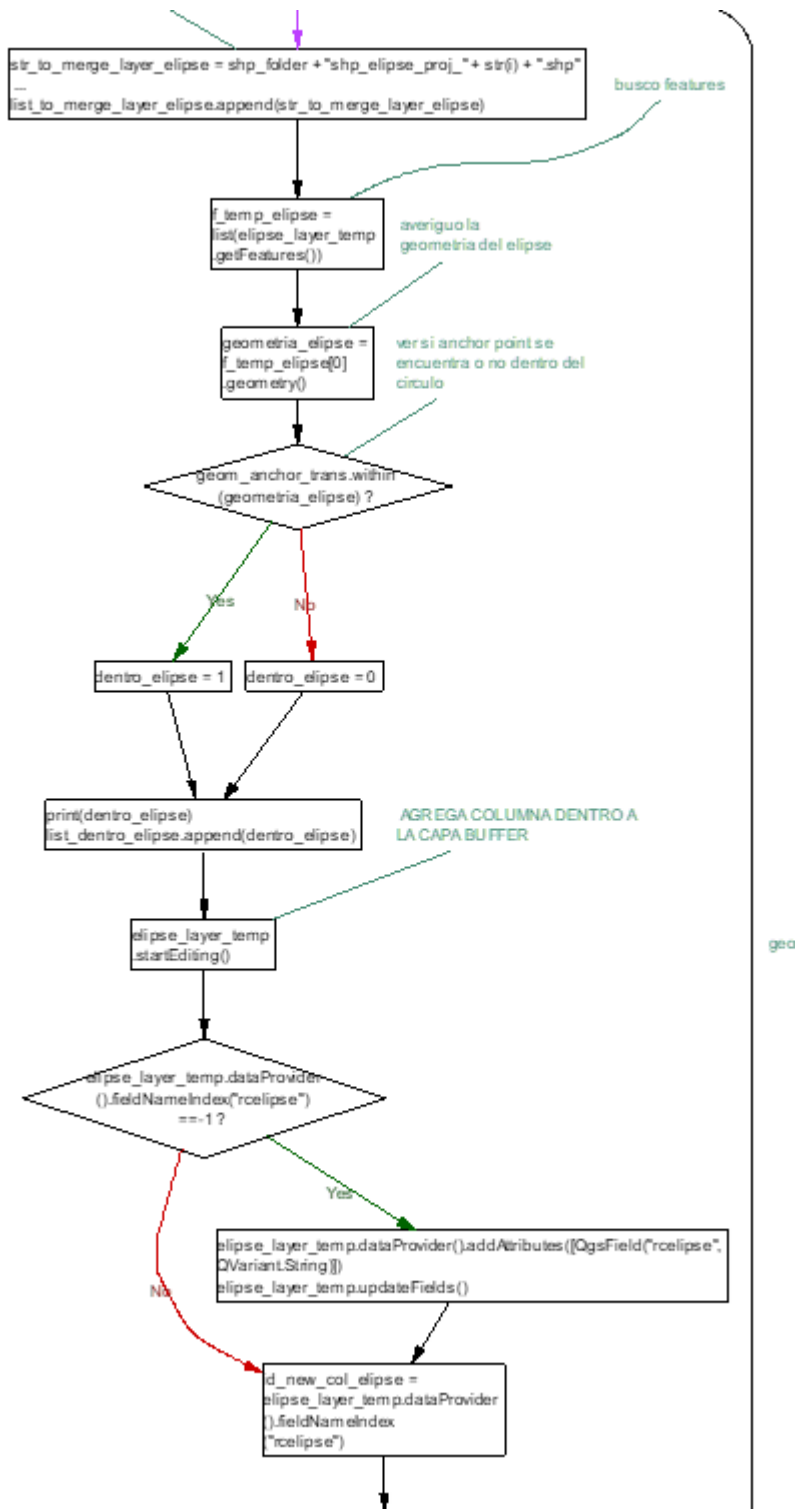
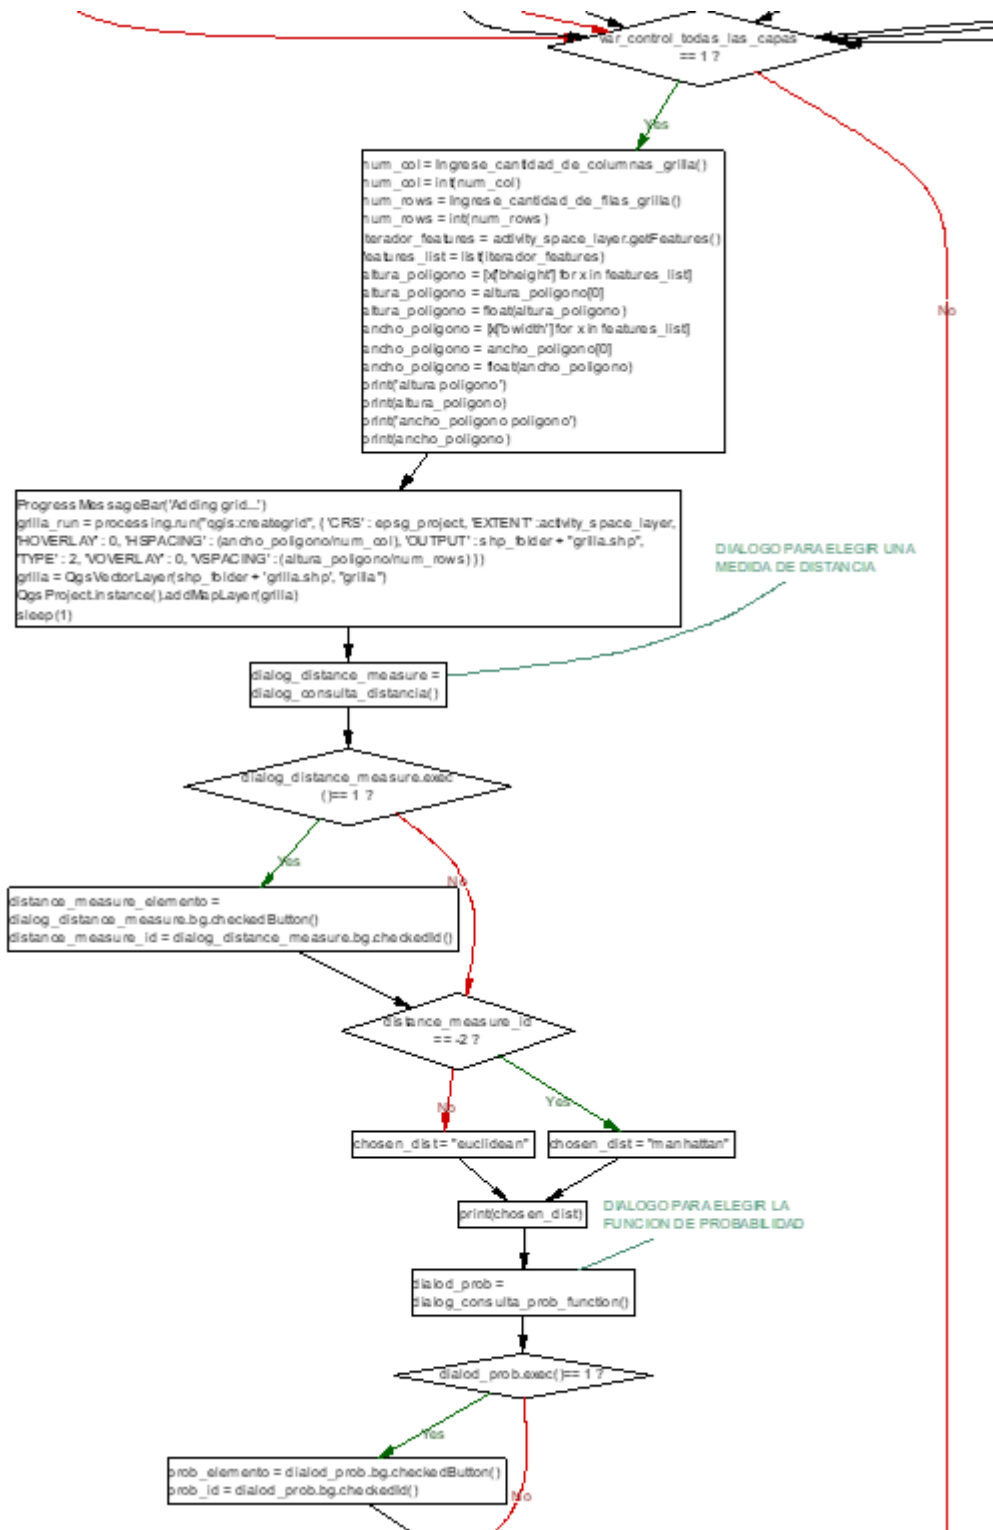


Figura 7-23 Diagrama de flujos. Estrategia de distribución de dispersión (Elipse)

## 7.2.9d Estrategia de distancia de probabilidad



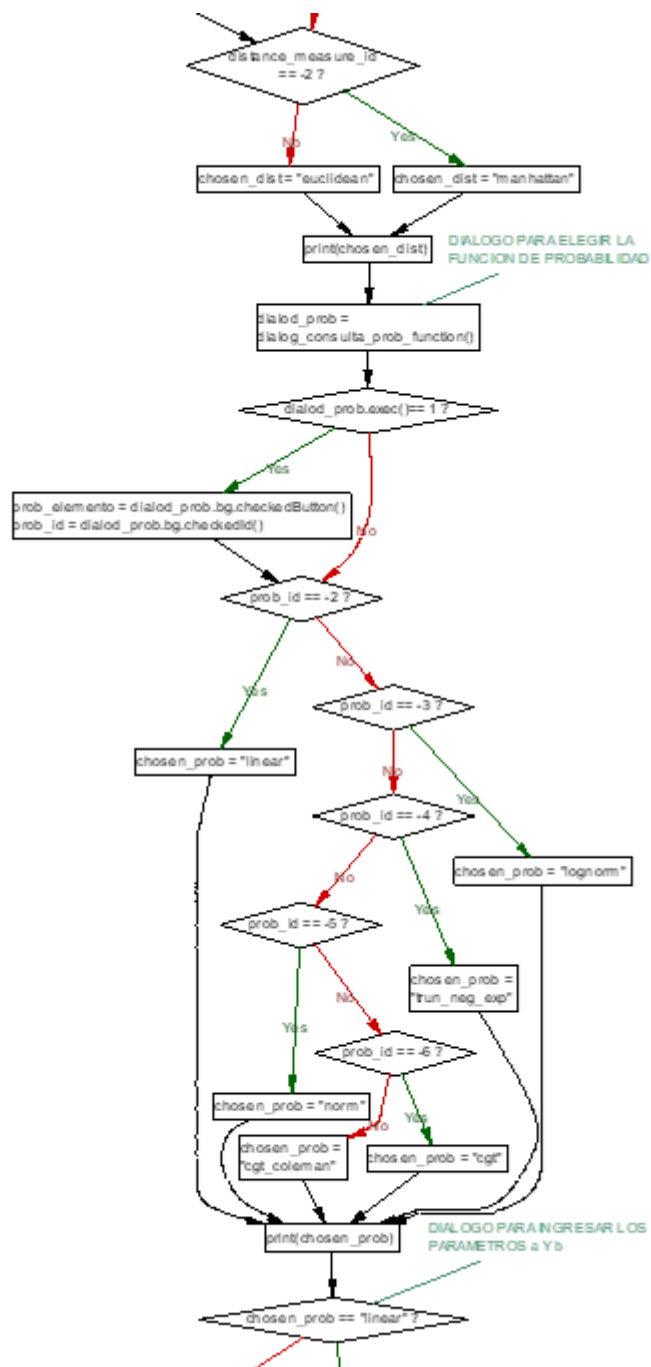


Figura 7-25 Diagrama de flujos. Estrategia de distancia de probabilidad