


UNIVERSIDAD MIGUEL HERNÁNDEZ DE
ELCHE ESCUELA POLITÉCNICA SUPERIOR DE
ELCHE

GRADO EN INGENIERÍA
INFORMÁTICA EN TECNOLOGÍAS DE
LA INFORMACIÓN




"Análisis y clasificación del control
atencional a partir de tareas cognitivas
mediante aprendizaje automático"

TRABAJO FIN DE GRADO

Febrero - 2026

AUTOR: Maria Isabel Salinas Perez
DIRECTORES: Alejandro Rabasa Dolado

Agradecimientos

Quiero darle las gracias a:

A todos los profesores que, a lo largo de estos años, me han acercado al mundo de la informática y han alimentado la curiosidad que sentía desde bien pequeña.

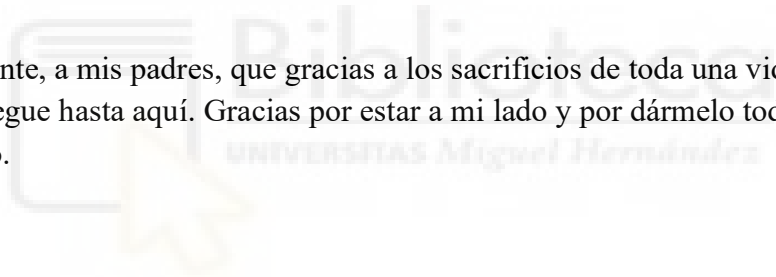
A Alejandro Rabasa, por su salero, simpatía y confianza, y por acompañarme y motivarme en esta etapa final del grado.

Al equipo Cobro-Iberdrola de Accenture Alicante y a Susana de Arriba por apoyarme tanto y ayudarme a llevarlo todo con humor.

Todos los compañeros que se convirtieron en buenos amigos, tanto Luisi's Army como el Club de Pádel de Málaga, que han hecho de esta etapa una experiencia inolvidable.

A Irene y Jorge, por ser mis modelos a seguir, por creer siempre en mí y por sostenerme cada vez que lo he necesitado.

Y, especialmente, a mis padres, que gracias a los sacrificios de toda una vida han hecho posible que llegue hasta aquí. Gracias por estar a mi lado y por dármele todo sin pedir nada a cambio.



Resumen

Este Trabajo de Fin de Grado se centra en el análisis del control atencional a partir de datos obtenidos en tareas cognitivas digitales. La atención es un proceso clave en el comportamiento humano, y su estudio se puede realizar mediante indicadores como tiempos de reacción, tasas de error o variabilidad en la respuesta. A partir de estas métricas sobre la conducta, el objetivo de este trabajo es explorar si es posible identificar patrones diferenciables utilizando técnicas de aprendizaje automático.

Para ello, se parte de un conjunto de datos procedente de tres tareas clásicas de evaluación atencional: Flanker, Stroop y Stop-Signal. Los datos originales, definidos a nivel de ensayo, se transforman mediante un proceso de preprocesamiento y construcción de características en una matriz agregada a nivel de participante.

Posteriormente, se sigue un enfoque de aprendizaje semi-supervisado. Es decir, en primer lugar, para definir perfiles experimentales, se utilizan técnicas de aprendizaje no supervisado y, a continuación, se aplican modelos supervisados para analizar su separabilidad y coherencia.

En este trabajo no se pretende optimizar al máximo el rendimiento de los modelos, sino analizar de forma clara los patrones que aparecen en los datos. Los resultados indican que las métricas conductuales permiten diferenciar perfiles, aunque estos dependan del conjunto de datos y no deben interpretarse como categorías definitivas.

En conjunto, el trabajo desarrolla un sistema modular en Python para el análisis de datos conductuales, combinando fundamentos teóricos de la atención con herramientas propias del análisis de datos y el aprendizaje automático.

Palabras clave: atención, tareas cognitivas, control inhibitorio, aprendizaje automático, análisis de datos, perfiles experimentales, Python.

Índice de contenido

CAPÍTULO 1. INTRODUCCIÓN	8
1.1. Contexto y motivación del estudio	8
1.2. Problema planteado y justificación	8
1.3. Objetivos	9
1.3.1. Objetivo general	9
1.3.2. Objetivos específicos	9
1.4. Alcance y limitaciones del trabajo	10
1.5. Estructura del documento	11
CAPÍTULO 2. ESTADO DE LA CUESTIÓN	12
2.1. La atención como función cognitiva	12
2.2. Modelos teóricos de la atención	12
2.3. Tareas cognitivas para la medición del rendimiento atencional	16
2.3.1. Tarea Flanker	16
2.3.2. Tarea Stroop	17
2.3.3. Tarea Stop-Signal	17
2.4. Aplicación del aprendizaje automático en el análisis cognitivo	19
2.5. Limitaciones identificadas en la literatura	20
2.6. Enfoque del presente trabajo en relación con estudios previos	21
Capítulo 3. METODOLOGÍA	22
3.1. Diseño general del estudio y flujo de trabajo	22
3.2. Descripción del conjunto de datos utilizado	23
3.3. Preprocesamiento del conjunto de datos	24
3.3.1. Variables crudas registradas	25
3.3.2. Construcción de características	26
3.4. Definición de perfiles experimentales mediante pseudo-etiquetado	29

3.5. Modelos de aprendizaje automático seleccionados	30
3.5.1. Árboles de decisión	30
3.5.2. Random Forest	31
3.5.3. Gradient Boosting (XGBoost)	31
3.5.4. Máquinas de Vectores de Soporte (SVM)	31
3.5.5. Aprendizaje por apilamiento (Stacking Ensemble)	32
3.6. Estrategia de entrenamiento y validación	32
3.7. Arquitectura del sistema y diseño del software	33
3.7.1. Diseño modular del sistema	35
3.7.2. Flujo de ejecución del sistema	35
3.8. Entorno tecnológico y herramientas utilizadas	36
3.8.1. Análisis y manipulación de datos	36
3.8.2. Aprendizaje automático y modelado	36
3.8.3. Visualización	37
Capítulo 4. RESULTADOS	38
4.1. Análisis exploratorio de las características	38
4.2. Resultados del aprendizaje no supervisado	40
4.3. Caracterización de perfiles experimentales	41
4.4. Resultados del aprendizaje supervisado	42
4.5. Análisis comparativo y visualización de resultados	43
4.6. Síntesis de los resultados	45
Capítulo 5. CONCLUSIONES Y TRABAJO FUTURO	46
5.1. Conclusiones	46
5.2. Limitaciones del estudio	47

5.3. Líneas de trabajo futuro	37
-------------------------------	----

Bibliografía	49
--------------	----

Índice de figuras

Figura 2.1 Modelo de las redes atencionales	12
Figura 2.2 Componentes del control atencional	14
Figura 3.1 Pipeline de preprocesamiento y construcción de características	25
Figura 3.2 Pipeline de modelado y análisis de perfiles experimentales	34
Figura 4.1 Matriz de correlación de las características derivadas	38
Figura 4.2 Evolución de la inercia (método del codo)	39
Figura 4.3 Proyección bidimensional mediante PCA	41
Figura 4.4 Mapa de calor de correlaciones entre características	42
Figura 4.5 Matriz de confusión del modelo Stacking Ensemble	44
Figura 4.6 Importancia de características mediante valores SHAP	44

Índice de tablas

Tabla 2.1 Resumen de las tareas cognitivas 19

Tabla 3.1 Variables derivadas extraídas de las tareas cognitivas 28



CAPÍTULO 1: INTRODUCCIÓN

1.1. Contexto y motivación del estudio

En los últimos años, el desarrollo de herramientas digitales y el uso de sistemas informáticos han permitido avanzar de forma significativa el análisis de datos en los procesos cognitivos humanos. Entre estos procesos, la atención es uno de los más estudiados, debido a su relación directa con el aprendizaje, la resolución de problemas y la toma de decisiones. Tradicionalmente, su estudio se ha llevado a cabo mediante pruebas neuropsicológicas en entornos controlados, lo que limitaba tanto la escalabilidad como la reutilización de los datos obtenidos desde un punto de vista computacional.

Con la aparición de tareas cognitivas informatizadas, se ha hecho posible la obtención de métricas conductuales objetivas de forma sistemática, gracias a que estas tareas generan datos cuantitativos como tiempos de reacción, tasas de acierto y error, así como medidas de variabilidad temporal. Por lo que ha supuesto un cambio relevante en el contexto de la psicología cognitiva. Desde la perspectiva computacional, este tipo de datos plantea nuevos retos relacionados con su estructuración, tratamiento y modelado.

Paralelamente, el aprendizaje automático se ha consolidado como una herramienta clave para el análisis de grandes volúmenes de datos, permitiendo identificar patrones y relaciones complejas que no resultaban evidentes mediante los métodos tradicionales. La combinación de datos procedentes de tareas cognitivas digitales y técnicas de aprendizaje automático hace posible la exploración de la estructura de esta información con un enfoque técnico.

La motivación principal de este trabajo surge de esta combinación entre el análisis de datos y el estudio de métricas conductuales asociadas a la atención. Se plantea la posibilidad de diseñar un sistema que permita procesar y analizar este tipo de datos de forma estructurada, explorando si es posible identificar patrones diferenciables mediante técnicas de aprendizaje automático, siguiendo un enfoque de ingeniería informática

1.2. Problema planteado y justificación

Los datos procedentes de las tareas cognitivas digitales presentan unas características que dificultan su análisis directo mediante técnicas de aprendizaje automático. En

primer lugar, los registros no están preparados para su uso inmediato en modelos computacionales, ya que se obtienen a nivel de ensayo individual, generando conjunto de datos extensos y heterogéneos. En segundo lugar, estas bases de datos carecen de etiquetas asociadas a categorías diagnósticas, lo que limita la aplicación de técnicas de aprendizaje supervisado.

Desde una perspectiva técnica, esto se plantea como un problema relacionado con el diseño de pipelines para el procesamiento de datos capaces de transformar información cruda en representaciones estructuradas y comparables. El proceso requiere realizar tareas como limpieza de datos, agregación de variables, selección y construcción de características y la evaluación de los modelos para garantizar la coherencia y la reproducibilidad de los datos.

El presente trabajo se justifica como una oportunidad para aplicar técnicas de aprendizaje automático al análisis de métricas conductuales desde una perspectiva técnica y exploratoria. El objetivo no es realizar interpretaciones clínicas ni diagnósticas, sino evaluar la capacidad de los modelos para distinguir patrones en los datos disponibles.

1.3. Objetivos

El objetivo general de este proyecto es diseñar e implementar un sistema de análisis de datos que permita explorar y discriminar patrones de rendimiento conductual a partir de métricas obtenidas en tareas cognitivas digitales, empleando técnicas de aprendizaje automático.

Para lograr los objetivos generales, se proponen los siguientes objetivos específicos:

1. Analizar las tareas cognitivas seleccionadas y las métricas conductuales que generan, desde una perspectiva orientada al análisis de datos.
2. Diseñar un proceso de preprocesamiento que permita transformar los registros a nivel de ensayo en un conjunto de características a nivel de participante.

3. Aplicar técnicas de aprendizaje no supervisado para explorar la estructura interna del espacio de características y definir agrupaciones basadas en patrones conductuales.
4. Entrenar y evaluar distintos modelos de aprendizaje supervisado con el fin de analizar su capacidad para distinguir los patrones definidos.
5. Estudiar la importancia de las características utilizadas y analizar las limitaciones del sistema propuesto.

1.4. Alcance y limitaciones del trabajo

El presente trabajo se centra en el análisis de datos procedentes de unas tareas cognitivas digitales. En ningún caso se pretende realizar diagnósticos, ni evaluar trastornos de la atención ni sustituir pruebas neuropsicológicas. Los patrones y agrupaciones obtenidos deben interpretarse como construcciones experimentales derivadas de la estructura de datos analizados.

De la misma manera, los resultados están condicionados por las características de los conjuntos de datos utilizados, como el tamaño de las muestras y el diseño de las tareas.

1.5. Estructura del documento

El documento se organiza en cinco capítulos. En el primer capítulo se presenta el contexto del trabajo, el problema abordado, los objetivos y el alcance del estudio. El segundo capítulo expone el estado de la cuestión, revisando los principales conceptos relacionados con la atención, las tareas cognitivas empleadas y el uso del aprendizaje automático en este ámbito.

El tercer capítulo describe la metodología seguida, incluyendo el diseño del sistema, el preprocesamiento de los datos, construcción de características y los modelos de aprendizaje automático utilizados. En el cuarto capítulo se presentan los resultados

obtenidos y su análisis. Finalmente, el quinto capítulo recoge las conclusiones del trabajo y plantea posibles líneas de investigación futura.



CAPÍTULO 2. ESTADO DE LA CUESTIÓN

2.1. La atención como función cognitiva

La atención constituye una de las funciones cognitivas más relevantes en el procesamiento de la información, al actuar como un mecanismo de selección que permite priorizar ciertos estímulos frente a otros en función del entorno y de los objetivos del individuo. Este proceso es esencial para la ejecución de tareas cognitivas, ya que regula la asignación de recursos limitados y condiciona el rendimiento conductual observable (Kahneman, 1973).

Desde una perspectiva teórica, la atención no se concibe como un proceso unitario, sino como un sistema compuesto por diferentes mecanismos funcionales que interactúan entre sí. Posner y Petersen (1990) propusieron un modelo en el que la atención se organiza en distintas redes funcionales especializadas, responsables de aspectos como la alerta, la orientación y el control ejecutivo. Este enfoque ha sido adoptado en la literatura posterior y se ha utilizado como marco de referencia para el estudio del comportamiento atencional en distintos contextos experimentales (Petersen & Posner, 2012).



Figura 2.1. Modelo de las redes atencionales (Posner y Petersen, 1990)

Diversos modelos han descrito la atención como un proceso de selección que filtra la información relevante y reduce la interferencia de otros estímulos. En modelos clásicos de selección temprana, como el propuesto por Broadbent (1958), la atención actúa como un filtro que limita el acceso de la información al procesamiento cognitivo posterior. Posteriormente, en la teoría de la competencia sesgada de Desimone y Duncan (1995),

se plantea que múltiples estímulos compiten por los recursos atencionales disponibles, siendo esta competencia modulada tanto por características del estímulo como por mecanismos de control voluntario.

En la literatura contemporánea, se distingue entre procesos atencionales de tipo bottom-up, asociados a la captación automática de estímulos salientes, y procesos top-down, asociados al control voluntario de la atención guiado por los objetivos del individuo. Esta distinción es especialmente relevante para el análisis del comportamiento, ya que se refleja en patrones diferenciables de tiempos de reacción, tasas de error y variabilidad en la respuesta ante diferentes condiciones experimentales (Desimone & Duncan, 1995; Petersen & Posner, 2012).

Desde la perspectiva de aplicación, el estudio de la atención suele apoyarse en medidas de rendimiento conductual obtenidas a partir de experimentales estandarizadas. Variables como los tiempos de reacción, la precisión de las respuestas o la variabilidad temporal forman indicadores indirectos del funcionamiento de la atención, permitiendo aproximar este proceso cognitivo a partir de datos cuantificables (Parasuraman, 1998). Estas métricas proporcionan una base para su análisis mediante técnicas computacionales, facilitando la aplicación de procesamiento de datos y aprendizaje automático en el estudio del rendimiento atencional.



Figura 2.2. Representación de los principales componentes del control atencional en tareas cognitivas. Barzykowski (2022)

2.2. Modelos teóricos de la atención

A lo largo de las últimas décadas se han propuesto múltiples modelos teóricos con el objetivo de explicar los mecanismos que constituyen el funcionamiento de la atención. Aunque los distintos enfoques difieren en la descripción de las etapas del procesamiento y el momento en el que actúa la atención, la mayoría coincide en considerarla como un proceso clave para la regularización del comportamiento y el uso eficiente de los recursos cognitivos.

Los primeros modelos teóricos de la atención conciben la atención como un mecanismo de selección temprana. En ese contexto, Broadbent (1958) propuso el modelo de filtro, donde la información sensorial es procesada inicialmente de forma paralela, pero solo los estímulos que superan un filtro acceden a etapas posteriores de procesamiento. Este enfoque introdujo la idea de que la atención actúa como un sistema que limita la información, protegiendo al sistema cognitivo de la sobrecarga.

Posteriormente Treisman (1964) planteó el modelo de atenuación, en el que los estímulos no atendidos no se bloquean completamente, sino que se procesan con menor intensidad. Con este planteamiento se adoptó una visión más flexible del sistema atencional, haciendo posible explicar fenómenos experimentales que no podían justificarse con un filtro estrictamente temprano. Estos dos modelos sentaron las bases para el estudio de la selección de información relevante frente a estímulos distractores.

Frente a los enfoques de selección temprana, surgieron los modelos de selección tardía, como el propuesto por Deutsch y Deutsch (1963), que asumen que todos los estímulos son procesados inicialmente y que la atención interviene en fases posteriores del reconocimiento o de la respuesta. Estos modelos destacaron la importancia de la atención en la toma de decisiones y en la ejecución de la respuesta, ampliando así la comprensión del proceso atencional más allá del perceptivo.

Desde una perspectiva neurocognitiva, varios estudios han identificado la existencia de redes neuronales diferenciadas implicadas en estos procesos. Corbetta y Shulman (2002) describen una red dorsal asociada al control atencional dirigido por objetivos y una red ventral relacionada con la detección automática de estímulos relevantes. Esta distinción ha sido utilizada para interpretar resultados obtenidos en tareas cognitivas que generan conflictos atencionales, como las tareas Stroop o Flanker.

Aunque estos modelos teóricos proporcionan un marco conceptual sólido para comprender la atención, el presente trabajo no pretende validarlos ni compararlos. En su lugar, se utilizan como referencia para contextualizar el análisis de métricas conductuales obtenidas en las tareas experimentales. Desde un enfoque computacional, el interés de este trabajo se centra en los resultados observables del comportamiento, como los tiempos de reacción y las tasas de error, reflejan la interacción de estos mecanismos atencionales y pueden ser analizadas mediante técnicas de aprendizaje automático.

2.3. Tareas cognitivas para la medición del rendimiento atencional

Las tareas cognitivas experimentales constituyen una de las principales herramientas para el estudio del rendimiento atencional. Estas tareas se basan en la presentación controlada de estímulos y en el registro sistemático de las respuestas del participante, lo que permite la obtención de datos cuantificables sobre comportamiento observable. Al contrario que las evaluaciones subjetivas, ya que este tipo de pruebas genera medidas precisas que pueden ser analizadas desde una perspectiva computacional.

Desde el contexto del análisis de datos e ingeniería informática, las tareas cognitivas son especialmente relevantes porque producen conjuntos de datos estructurados y repetibles. En cada ensayo se registra variables como el tipo de estímulo presentado, la respuesta, la corrección de dicha respuesta y el tiempo de reacción. La agregación de estos registros permite la construcción de métricas que describen el rendimiento de cada participante de forma compacta y comparable.

En el presente trabajo se emplean tres tareas cognitivas utilizadas en la literatura para evaluar distintos componentes del control atencional: la tarea Flanker, la tarea Stroop y la tarea Stop-Signal. Estas pruebas se caracterizan por generar conflictos atencionales controlados que pueden reflejar los patrones diferenciables de comportamiento, facilitando el análisis de métricas conductuales mediante técnicas de aprendizaje automático.

2.3.1. Tarea Flanker

La tarea Flanker fue introducida por Eriksen y Eriksen (1974) con el objetivo de evaluar la capacidad del sistema atencional para filtrar información irrelevante en presencia de estímulos distractores. En este paradigma, el participante debe responder a un estímulo objetivo central ignorando estímulos periféricos que pueden ser congruentes o incongruentes con la respuesta correcta.

Los ensayos incongruentes suelen asociarse a tiempos de reacción más elevados y a un aumento en la tasa de errores, reflejando un mayor coste atencional debido a los estímulos distractores. Estas diferencias permiten calcular métricas de interferencia que cuantifican la eficiencia del control atencional del participante.

En el contexto del análisis de datos, la tarea Flanker genera variables adecuadas para la construcción de características relacionadas con la atención selectiva, como diferencias de tiempo de reacción entre condiciones congruentes e incongruentes, porcentajes de error o medidas de variabilidad temporal.

2.3.2. Tarea Stroop

La tarea Stroop, introducida por John Ridley Stroop en 1935, es uno de los paradigmas más utilizados para evaluar el control inhibitorio y la capacidad de suprimir respuestas automáticas. En esta tarea, el participante debe indicar una característica relevante del estímulo, ignorando su sentido semántico, lo que genera conflicto cognitivo, lo que genera un conflicto cognitivo en los ensayos incongruentes.

Este efecto, conocido como efecto Stroop se manifiesta en un incremento de tiempos de reacción y una disminución de la precisión cuando existe una incongruencia entre el significado de la palabra y el color que se presenta. Estas diferencias permiten construir indicadores del grado de interferencia cognitiva experimentado por el participante.

Desde una perspectiva computacional, la tarea Stroop resulta útil para el análisis del control atencional, ya que permite la generación métricas derivadas como índices de interferencia, tasas de error específicas por condición y medidas

agregadas de rendimiento que pueden ser empleadas como variables de entrada en modelos de aprendizaje automático.

2.3.3. Tarea de Stop-Signal

La tarea Stop-Signal fue introducida inicialmente por Lappin y Eriksen (1966) y desarrollada posteriormente por Logan y Cowan (1984), está diseñada para evaluar la capacidad de inhibición de respuestas ya iniciadas, es decir, participante debe responder rápidamente a estímulos de tipo “go”, pero inhibir la respuesta cuando aparece una señal de parada.

Este tipo de inhibición no se limita a la supresión de tendencias automáticas, sino que implica la interrupción activa de un proceso ya en ejecución. La capacidad de controlar la respuesta tras la señal de detención refleja el control ejecutivo y la regulación del impulso, proporcionando información sobre la dinámica inhibitoria del sistema cognitivo.

Esta tarea permite obtener métricas relacionadas con errores de comisión y omisión, así como medidas temporales asociadas a la variabilidad en los tiempos de reacción. Estas variables reflejan la eficiencia del control inhibitorio y de la atención sostenida durante la ejecución de la tarea.

Para el análisis de datos, la tarea Stop-Signal proporciona información complementaria a la obtenida en tareas como Stroop o Flanker, ya que introduce un componente relacionado con la interrupción de respuestas en curso. Las métricas derivadas de esta tarea permiten alimentar el espacio de características y capturar distintos aspectos del rendimiento atencional desde una perspectiva cuantitativa.

Tarea	Proceso evaluado	Métricas principales generadas	Aportación computacional clave
Flanker	Atención selectiva	Diferencias RT congruente/incongruente, tasa de error, variabilidad	Interferencia atencional
Stroop	Control inhibitorio	Índice de interferencia, RT por condición, precisión	Conflicto cognitivo
Sart	Inhibición de respuesta	Errores de comisión/omisión, variabilidad RT, tiempos de reacción	Control inhibitorio dinámico

Tabla 2.1. Resumen de las tareas cognitivas

2.4. Aplicación del aprendizaje automático en el análisis cognitivo

En los últimos años, el aprendizaje automático se ha consolidado como una herramienta clave para el análisis de datos conductuales y cognitivos, gracias a su capacidad para modelar relaciones complejas y detectar patrones en conjuntos de datos de alta dimensionalidad. A diferencia de los enfoques estadísticos tradicionales, estas técnicas permiten trabajar con grandes volúmenes de datos, capturar interacciones no lineales entre variables, especialmente útil en el estudio del comportamiento humano.

Los datos procedentes de las tareas cognitivas pueden representarse como matrices de características que combinan variables continuas y categóricas. No obstante, estos datos suelen necesitar una fase de preprocesamiento que incluya limpieza de registros, normalización de las variables y construcción de métricas que permita representar el comportamiento de forma compacta y comparable.

Diversos estudios han aplicado técnicas de aprendizaje automático tanto supervisadas como no supervisadas para analizar el rendimiento cognitivo, explorar perfiles conductuales o predecir resultados asociados a tareas experimentales. En los casos donde se aplica aprendizaje no supervisado, se explora la estructura interna de los datos y detectar agrupaciones basadas en patrones de comportamiento, mientras que los modelos supervisados evalúan la separabilidad de dichos patrones y analizan la importancia relativa de las características utilizadas.

Desde el contexto de análisis de datos, el interés principal de estas aproximaciones está en su capacidad para transformar datos conductuales complejos en representaciones mediante modelos automáticos. En este sentido, el aprendizaje automático se plantea como una herramienta de apoyo al análisis de datos cognitivos, más que como un mecanismo de interpretación psicológica.

2.5. Limitaciones identificadas en la literatura

El uso de tareas cognitivas estandarizadas como la fuente de datos para el análisis de los patrones de la atención presenta algunas limitaciones. Una de las más determinantes es la variabilidad interindividual, que de alguna manera influye en las medidas obtenidas en las pruebas cognitivas, sobre todo en variables como el tiempo de reacción o la tasa de errores. Esta variabilidad puede ser afectada por factores como la fatiga, el estado emocional, familiaridad con las tareas digitales o las características del dispositivo utilizado para su realización.

Otra limitación es el tamaño reducido de las pruebas, problema bastante frecuente en estudios cognitivos experimentales, lo que dificulta la generalización de los resultados y puede afectar al rendimiento de los modelos.

Asimismo, también se considera la heterogeneidad en la metodología de los diferentes experimentos de los que se recolectan los datos. Es decir, existen varias versiones de las mismas tareas, por ejemplo, en la variación en la duración, número de ensayos o el tiempo de exposición a los estímulos. Esto dificulta la comparación entre trabajos y limita la opción de reutilizar datasets sin un proceso de preprocesamiento previo.

En el caso de este trabajo, se señala también la ausencia de etiquetas asociadas a categorías cognitivas o diagnósticas, que limita la aplicación de enfoques supervisados y obliga a recurrir a estrategias exploratorias. Estas limitaciones hacen evidente la necesidad de diseñar pipelines de procesamiento y de interpretar los resultados obtenidos con cautela, evitando extrapolaciones que no estén respaldadas por los datos.

2.6. Enfoque del presente trabajo en relación con estudios previos

Este estudio se apoya en estudios previos en los que se realizaron tareas cognitivas para el estudio del rendimiento atencional. Pero se diferencia de muchas de ellas en el enfoque adoptado, que se aplica con una finalidad diagnóstica o comparativa, el enfoque de este proyecto no es diagnóstico, si no que se centra en el análisis técnico y exploratorio de métricas conductuales desde una perspectiva de ingeniería informática.

Por otra parte, este trabajo propone un enfoque basado en el diseño de un sistema modular de procesamiento de datos que transforma los registros experimentales a nivel de ensayo en un conjunto estructurado de características a nivel de participante. Con esta representación, se utilizan técnicas de aprendizaje automático para explorar la estructura de los datos y evaluar la capacidad de los modelos para encontrar diferentes patrones de comportamiento.

De este modo, el valor de este estudio no reside en la interpretación psicológica de los resultados, sino en la implementación y evaluación de un pipeline de análisis que integra preprocesamiento de datos, construcción de características y modelado automático. Este enfoque sitúa el trabajo en un punto intermedio entre la investigación cognitiva experimental y el análisis de datos, aportando una perspectiva técnica aplicada al estudio del rendimiento atencional.

Capítulo 3: Metodología

En este capítulo se describe la metodología seguida para la realización del análisis de métricas conductuales, así como el diseño e implementación del sistema para su procesamiento y análisis mediante técnicas de aprendizaje automático. También se detallan las fuentes de datos utilizadas, las fases de preprocesamiento, la construcción de características, los métodos de aprendizaje automático empleados y las estrategias de validación utilizadas, todo esto desde una aplicación orientada al análisis de datos.

3.1. Diseño general del estudio y flujo de trabajo

El presente estudio tiene un enfoque propio del análisis de datos experimentales, combina técnicas de preprocesamiento, análisis exploratorio y aprendizaje automático para identificar patrones conductuales desde resultados obtenidos en tareas cognitivas digitales. El objetivo en este capítulo es diseñar un pipeline de procesamiento que haga posible la transformación de los datos en representaciones para su análisis.

Todo esto parte de la combinación de tres conjuntos de datos procedentes de una investigación previa, cada uno asociado a una tarea cognitiva distinta. Estos conjuntos contienen información detallada sobre los tiempos de reacción, precisión de la respuesta y condiciones experimentales, lo que permite caracterizar el comportamiento de cada participante. A partir de estos registros, se construye un conjunto de características agregadas a nivel de participante resumiendo su rendimiento en cada tarea.

Para la ejecución del proceso, se ha desarrollado un sistema modular en Python, con una estructura orientada a pipelines de ciencia de datos. Con esta organización es posible separar claramente los datos, la lógica de preprocesamiento, el modelado y la visualización de los datos.

Los datos experimentales se almacenan diferenciando entre datos crudos y procesados, mientras que la lógica del procesamiento, el modelado y la visualización. De forma complementaria, se utilizan notebooks para el análisis exploratorio y la experimentación con los modelos, facilitando la validación de decisiones metodológicas antes de su integración en el sistema.

3.2. Descripción del conjunto de datos utilizado

Para el desarrollo del proyecto se ha seleccionado un conjunto de datos procedente del estudio *Cognitive inhibition behavioral tasks in online and laboratory settings* (Barzykowski, Wereszczyński, Hajdas & Radel, 2022). Dicha investigación pone a disposición de la comunidad científica un conjunto de datasets que recogen el rendimiento de los participantes en distintas tareas cognitivas orientadas a la medición de la atención y el control inhibitorio.

El conjunto de datos recoge la participación de 485 participantes en las tareas cognitivas, generando así más de 12000 registros por tarea, lo que proporciona una base de datos con el tamaño suficiente para aplicar técnicas de análisis estadístico y aprendizaje automático.

Los datos se encuentran divididos en tres ficheros independientes, uno por cada tarea. En todos los casos, cada fila representa un ensayo individual realizado por un participante. Los ficheros están estructurados de forma similar, incluyendo identificadores de los sujetos, la duración de la sesión y variables específicas de cada tarea, como el tipo de estímulo presentado, la respuesta del sujeto, la latencia o el tiempo de reacción.

El dataset de la tarea Stroop incluye variables relacionadas con la congruencia semántica del estímulo, la respuesta del sujeto, la corrección de dicha respuesta y los tiempos de reacción. El fichero correspondiente de la tarea Flanker contiene información sobre la congruencia entre el estímulo central y distractores, precisión y latencia. Y por último, en el caso del dataset de la tarea fz, recoge variables asociadas a las tareas go/no-go, errores por comisión y emisión, tiempos de reacción y contadores acumulativos de respuestas.

3.3 Preprocesamiento del conjunto de datos

Aunque el nivel de granularidad de los datos es adecuado para el análisis experimental, no resulta compatible con la aplicación directa de modelos de aprendizaje automático a nivel de participante. Por este motivo, el preprocesamiento constituye una etapa fundamental del sistema, ya que permite transformar los registros experimentales en una representación estructurada, coherente y reproducible del comportamiento de cada individuo.

El objetivo de esta etapa es preparar los datos para su uso en modelos de aprendizaje automático y así garantizar coherencia, calidad y reproducibilidad de los datos. Para ello, se plantea como un proceso sistemático, independiente del análisis e integrado en el pipeline del sistema. Esta separación garantiza que las transformaciones de los datos sean reproducibles de forma consistente, al margen de la experimentación inicial en los notebooks.



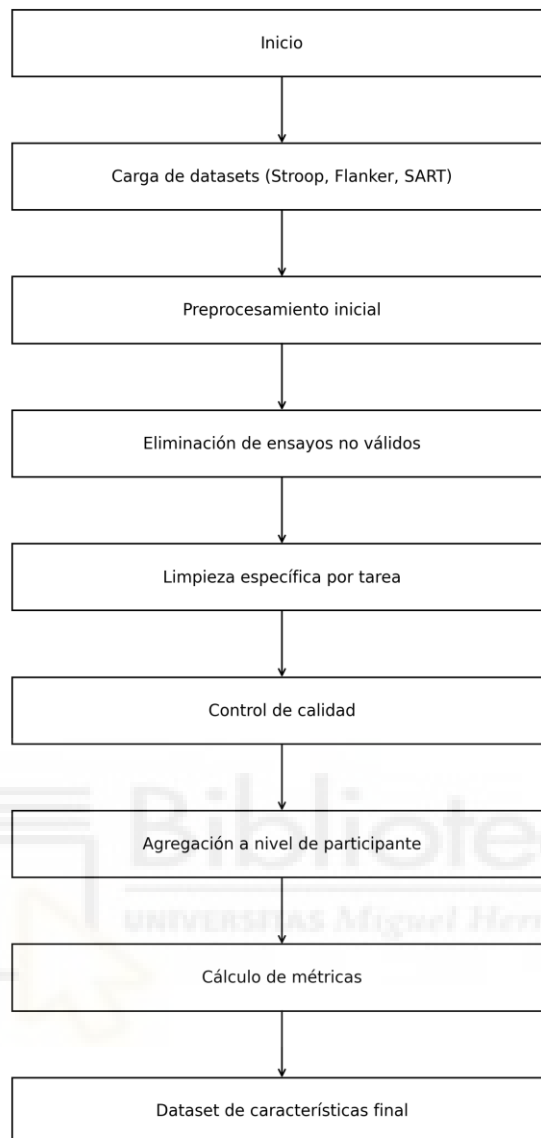


Figura 3.1. Pipeline de preprocesamiento y construcción de características

3.3.1 Variables crudas registradas

Los datos utilizados se encuentran en tres ficheros independientes, uno por cada tarea cognitiva. En todos los casos, cada fila representa un ensayo individual, identificado por un identificador único de sujeto.

En el dataset de la tarea Flanker, se incluye variables relacionadas con la congruencia entre el estímulo objetivo y los estímulos distractores, indicadores de corrección de la respuesta y tiempos de reacción en milisegundos. Estas variables posibilitan el análisis

del impacto de la interferencia atencional sobre el rendimiento del participante, especialmente en términos de latencia y precisión.

Para la tarea Stroop, el conjunto de datos contiene información sobre la congruencia semántica del estímulo, la respuesta emitida, la corrección de la respuesta y los tiempos de reacción. Este conjunto permite cuantificar el efecto Stroop con la comparación del rendimiento en ensayos congruentes e incongruentes.

En el caso de la tarea Stop-Signal (Sart), el conjunto de datos tiene una estructura más compleja, con variables que distinguen ensayos Go y No-Go, indicadores de corrección de la respuesta, tiempos de reacción y contadores de respuesta. Con estas variables, se identifican errores por comisión y omisión y analizar la variabilidad temporal del tiempo de respuesta.

3.3.2 Construcción de características

La construcción de características forma parte de una de las fases más importantes del proceso, ya que hace de puente entre los registros originales y el modelado. En esta etapa, los datos definidos a nivel de ensayo se transforman en un conjunto de variables numéricas agregadas a nivel de participante, haciendo el conjunto de datos más adecuado para su uso como entrada en los modelos de aprendizaje automático.

En primer lugar, se calculan estadísticas descriptivas para cada tarea y participante, tales como la media y la desviación típica de los tiempos de reacción. Con estas métricas se capturan tanto la velocidad de respuesta como la estabilidad temporal del rendimiento, reduciendo la influencia de la variabilidad de ensayos individuales. Esta agregación también disminuye la dimensionalidad del problema y mejora la robustez del conjunto de datos resultante.

Además, se definen indicadores para cada tarea cognitiva. En las tareas Flanker y Stroop se calculan índices de interferencia basados en las diferencias de tiempos de reacción y tasas de error entre ensayos congruentes e incongruentes. Estos indicadores permiten evaluar el efecto del conflicto cognitivo sobre el rendimiento y comparar a los participantes.

Para la tarea Stop-Signal, se incluyen también métricas con el fin de capturar aspectos relacionados con la atención sostenida y el control inhibitorio, como el coeficiente de variación de los tiempos de reacción, el número y porcentaje de errores por comisión y omisión, además de medidas temporales asociadas a respuestas correctas e incorrectas. Con estas características será posible representar de forma cuantitativa patrones de impulsividad o fluctuaciones en la atención.

Todas estas características derivadas se agrupan a nivel de participante mediante su identificador, generando así un único vector de características por sujeto. Este conjunto de datos final constituye la matriz de entrada para el aprendizaje automático.



Tarea	Tipo de métrica	Variable derivada	Descripción
Stroop	Tiempo de reacción	stroop_rt_mean	Media del tiempo de reacción
Stroop	Variabilidad	stroop_rt_std	Desviación típica del tiempo de reacción
Stroop	Interferencia	stroop_interference	Diferencia de RT entre ensayos incongruentes y congruentes
Flanker	Tiempo de reacción	flanker_rt_mean	Media del tiempo de reacción
Flanker	Variabilidad	flanker_rt_std	Desviación típica del tiempo de reacción
Flanker	Interferencia	flanker_interference	Diferencia de RT entre condiciones incongruente y congruente
SART	Tiempo de reacción	sart_rt_mean	Media del tiempo de reacción en ensayos Go
SART	Variabilidad	sart_cv	Coefficiente de variación del tiempo de reacción
SART	Error por comisión	sart_error_rate_commission	Porcentaje de respuestas incorrectas en ensayos No-Go

SART	Error por omisión	sart_error_rate_omission	Porcentaje de omisiones en ensayos Go
------	-------------------	--------------------------	---------------------------------------

Tabla 3.1. Variables derivadas extraídas de las tareas cognitivas

3.4. Definición de perfiles experimentales mediante pseudo-etiquetado

Para la aplicación de aprendizaje supervisado es necesario la disponibilidad de etiquetas asociadas a cada observación. Sin embargo, en el contexto de este trabajo, el conjunto de datos utilizado no contiene etiquetas clínicas, diagnósticas o categóricas que definan distintos tipos de rendimiento atencional. Esta ausencia de etiquetas es una limitación para el uso directo de modelos supervisados, pero al mismo tiempo abre la posibilidad de explorar otros enfoques basados en el análisis de la estructura de los datos.

Para abordar esta limitación, se introduce una fase intermedia basada en técnicas de aprendizaje no supervisado. Esta fase se añade con la finalidad de explorar la organización del espacio de características del comportamiento de los participantes y analizar si existen agrupaciones basadas en patrones de similitud conductual. Este enfoque permite estudiar la separabilidad de los datos sin incorporar información externa ni supuestos previos.

Estas técnicas no supervisadas se aplican en la matriz de características a nivel de participante, obtenida tras la fase de preprocesamiento y construcción de características descritas en apartados anteriores. Para facilitar la exploración de los datos, se utilizan técnicas de reducción de dimensionalidad y agrupamiento, que permiten identificar posibles patrones. Estas técnicas se utilizan como herramientas exploratorias, para comprender la distribución de los datos y detectar agrupaciones coherentes.

Los grupos obtenidos en el proceso se interpretan como perfiles experimentales, definidos a partir de la similitud en los patrones conductuales observados. Estos perfiles no representan ninguna categoría psicológica ni diagnóstico real, sino agrupaciones dependientes del conjunto de datos y las métricas consideradas. En este sentido, deben

entenderse como una abstracción metodológica para el análisis posterior, no como una clasificación definitiva del rendimiento atencional.

Con el fin de evaluar la coherencia de las agrupaciones y su utilidad en fases posteriores del análisis, estos perfiles experimentales se utilizan como pseudo-etiquetas en el entrenamiento de modelos de aprendizaje supervisado. Este enfoque entra dentro de una estrategia de aprendizaje semi-supervisado y permite analizar la capacidad de distintos modelos para discriminar entre patrones conductuales definidos.

3.5 Modelos de aprendizaje automático seleccionados

La selección de los modelos de aprendizaje automático se ha realizado teniendo en cuenta criterios técnicos relacionados con la naturaleza del conjunto de datos y los objetivos del estudio. Dado que dataset final presenta una estructura tabular, un número moderado de observaciones y posibles relaciones no lineales entre las variables, se ha optado por emplear un conjunto de modelos complementarios que permitan analizar la estabilidad y coherencia de los patrones identificados desde distintas perspectivas.

El uso de múltiples modelos no se justifica en la obtención de un único clasificador óptimo, sino la evaluación comparativa de la capacidad de distintas arquitecturas para distinguir diferentes patrones definidos mediante el proceso de pseudo-etiquetado.

3.5.1 Árboles de decisión

Los árboles de decisión son modelos supervisados que construyen una estructura jerárquica de reglas a partir de las variables de entrada, dividiendo el espacio de características en regiones cada vez más homogéneas respecto a la etiqueta objetivo. Este enfoque se basa en los modelos CART (Breiman et al., 1984), muy utilizados en tareas de clasificación y regresión.

En este estudio se utilizan como modelo base de referencia, proporcionando una primera aproximación a la estructura de los datos y facilitando el análisis de la importancia de las características del rendimiento conductual.

3.5.2 Random Forest

El algoritmo Random Forest combina múltiples árboles de decisión entrenados sobre subconjuntos aleatorios de datos y variables, reduciendo la varianza del modelo y mejorando su capacidad de generalización. Cada árbol realiza una predicción y la clasificación final se obtiene mediante votación. El método fue propuesto por Breiman (2001) como una extensión basada en la agregación de múltiples árboles.

En este trabajo se utiliza para analizar la estabilidad de los patrones identificados en comparación con un árbol individual. Además, permite estimar la importancia relativa de las características, útil para comparar las métricas conductuales más relevantes.

3.5.3. Gradient Boosting (XGBoost)

Los métodos de Gradient Boosting construyen modelos de forma secuencial, añadiendo árboles de decisión de manera iterativa para corregir los errores cometidos por los modelos anteriores. A diferencia de Random Forest, el boosting optimiza una función de pérdida mediante descenso de gradiente. Este enfoque se fundamenta en los trabajos de Friedman (2001) y ha sido implementado eficientemente en bibliotecas como XGBoost (Chen & Guestrin, 2016).

Se incorpora por su capacidad para capturar patrones complejos en datos tabulares y para contrastar el rendimiento de modelos más flexibles frente a otros más interpretables.

3.5.4. Máquinas de Vectores de Soporte (SVM)

Las Máquinas de Vectores de Soporte son modelos supervisados que buscan la frontera de decisión óptima entre clases, maximizando la distancia respecto a los puntos más cercanos de cada grupo. Este modelo fue introducido por Cortes y Vapnik (1995) y ha sido ampliamente utilizado en problemas de clasificación de alta dimensionalidad.

Se seleccionan por su eficacia en contextos donde el número de variables es elevado en relación con el número de observaciones. Su inclusión aporta una perspectiva complementaria a los modelos basados en árboles.

3.5.5. Aprendizaje por apilamiento (Stacking Ensemble)

Para integrar la información generada por los distintos modelos se emplea una arquitectura de aprendizaje por apilamiento (*stacking*). Esta técnica entrena un meta-modelo que utiliza como entrada las predicciones de los modelos base.

En este estudio se utiliza para analizar si la combinación de enfoques mejora la estabilidad y coherencia en la discriminación entre perfiles experimentales. La técnica fue formalizada por Wolpert (1992) como un método de combinación de modelos mediante meta-aprendizaje.

3.6 Estrategia de entrenamiento y validación

Para evaluar el comportamiento de los modelos seleccionados, el dataset final se divide en un conjunto de entrenamiento y un conjunto de prueba, utilizando una proporción del 80% y 20%, respectivamente. Esta división se realizó de forma aleatoria, procurando mantener una distribución de los perfiles definidos mediante el proceso de pseudo-etiquetado.

Sobre el conjunto de entrenamiento se aplica un procedimiento de validación cruzada k-fold, con el objetivo de evaluar la estabilidad de los modelos y reducir la dependencia de una única partición de los datos. De esta manera, se obtiene una estimación más robusta del rendimiento y facilita la comparación entre las diferentes arquitecturas en condiciones similares.

El rendimiento de los modelos se evalúa con métricas de clasificación, como accuracy, precisión, recall, F1-score y la matriz de confusión. La finalidad de estas métricas es analizar la coherencia de los patrones identificados y la consistencia del comportamiento de los modelos ante distintas configuraciones.

3.7 Arquitectura del sistema y diseño del software

El desarrollo del presente trabajo se apoya en un sistema software diseñado de forma modular, basado en una pipeline de procesamiento de datos. Con este enfoque se puede

estructurar el flujo de trabajo en etapas diferenciadas, facilitando la mantenibilidad, reutilización del código y la reproducibilidad de los experimentos.

A nivel funcional, el sistema transforma los datos crudos, registrados a nivel de ensayo, en un conjunto estructurado de características a nivel de participante, que posteriormente se utiliza para el entrenamiento y evaluación de modelos de aprendizaje automático. Cada fase del proceso se implementa en módulos independientes, responsables de tareas específicas dentro del flujo de trabajo.

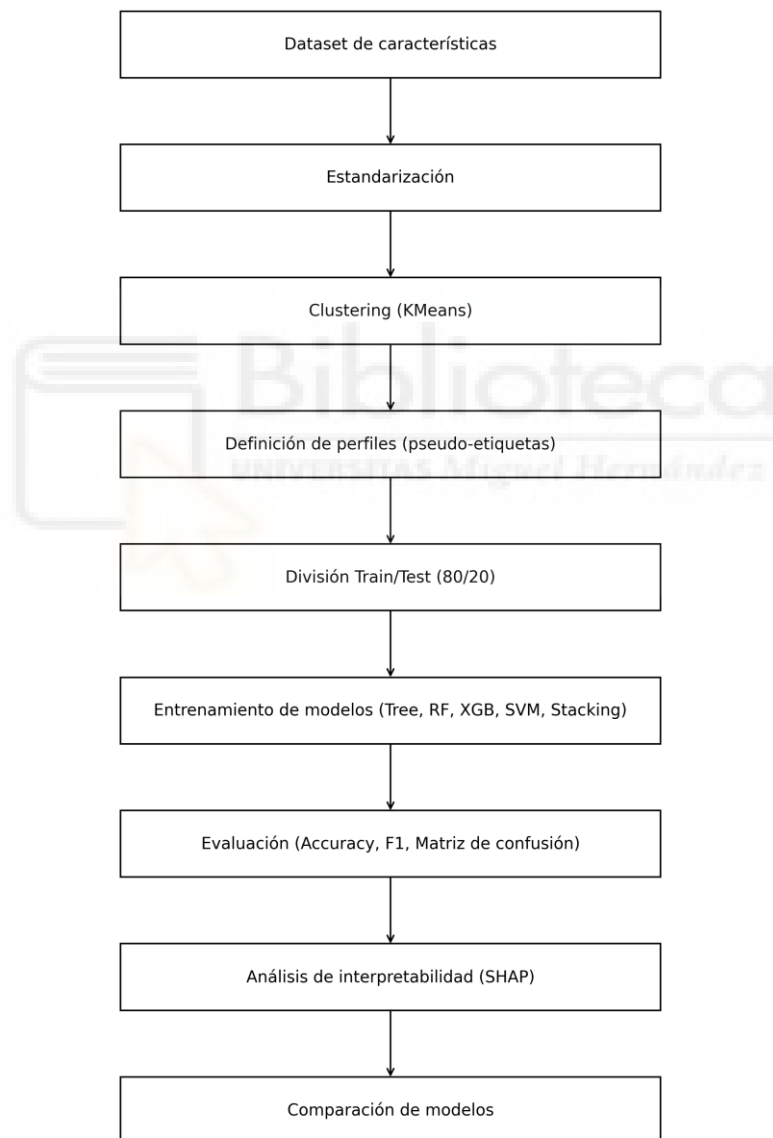


Figura 3.2. Pipeline de modelado y análisis de perfiles experimentales

3.7.1 Diseño modular del sistema

Desde una perspectiva estructural, el sistema se ha diseñado siguiendo un enfoque modular, en el que cada componente encapsula una funcionalidad concreta del proceso de análisis de datos. El código se organiza en los siguientes módulos principales:

- Carga y exploración de datos: responsable de la lectura de los ficheros originales correspondientes a cada tarea cognitiva y de la validación de las variables.
- Preprocesamiento de datos: donde se realiza la limpieza, filtrado de ensayos no válidos y depuración de registros inconsistentes.
- Construcción de características: dedicado a la generación de métricas agregadas por participante, incluyendo estadísticas descriptivas, índices de interferencia y medidas de variabilidad temporal.
- Modelado y aprendizaje automático: integra tanto las técnicas de aprendizaje no supervisado para el pseudo-etiquetado como los modelos supervisados para la clasificación de perfiles atencionales.
- Visualización y análisis de resultados: responsable de la representación gráfica de los resultados y de su interpretación.

Con esta organización modular se desacopla las diferentes fases del procesamiento de manera que cada componente puede modificarse o ampliarse de forma independiente sin afectar al resto del sistema.

3.7.2 Flujo de ejecución del sistema

Desde una perspectiva dinámica, el flujo de ejecución del sistema describe la secuencia de operaciones que se llevan a cabo desde la entrada de los datos hasta la obtención de los resultados. Es decir, en este apartado se explica el comportamiento del sistema durante su ejecución. El flujo de ejecución sigue una secuencia lineal definida de la siguiente manera:

1. Lectura de los datasets originales de las tareas cognitivas.
2. Aplicación de los procesos de limpieza y depuración de datos.

3. Generación de la matriz de características a nivel de participante.
4. Aplicación de técnicas de aprendizaje no supervisado para la definición de perfiles experimentales.
5. Entrenamiento y evaluación de los modelos de aprendizaje automático supervisados.
6. Análisis e interpretación de los resultados mediante visualización.

3.8. Entorno tecnológico y herramientas utilizadas

Para el desarrollo del proyecto, todo lo comentado en las secciones anteriores, desde el tratamiento de los datos brutos hasta la implementación y validación de los modelos, se ha implementado en un entorno de desarrollo basado en Python 3.12. Se ha elegido este lenguaje por su uso extendido en ciencia de datos y por contar con una alta disponibilidad de librerías especializadas para el análisis científico. Las herramientas utilizadas se nombran a continuación según su función en el flujo de trabajo:

3.8.1. Análisis y manipulación de datos

- Pandas: Herramienta principal para la conversión y tratamiento de los datos en dataframes, permite la limpieza, filtrado y agregación de las métricas por participante.
- NumPy: Utilizada para el manejo eficiente de las estructuras matriciales y realización de cálculos estadísticos y matemáticos complejos sobre los tiempos de reacción y tasas de acierto.

3.8.2. Aprendizaje automático y modelado

- Scikit-learn: Librería principal para la fase del modelado. Se utiliza para implementar los algoritmos, dividir la muestra, ejecutar el clasificador de Stacking y, por último, también se ha empleado su módulo de métricas para la evaluación del rendimiento.
- XGBoost: Utilizada para la implementación del modelo Gradient Boosting, por su capacidad de optimización y rapidez durante el entrenamiento de árboles secuenciales.

3.8.3. VisualizaciónM

- Matplotlib y Seaborn: Estas librerías se utilizan para generar la representación gráfica de los resultados, incluyendo también el análisis exploratorio, las matrices de confusión y las gráficas.



CAPÍTULO 4. RESULTADOS

4.1 Análisis exploratorio de las características

Antes de aplicar el modelado y el objetivo de estudiar la relación entre las distintas métricas, se realizó un análisis exploratorio de la matriz de características a nivel de participante. En la figura 4.1 se presenta la matriz de correlación correspondiente a las principales características derivadas de las tareas cognitivas.




Figura 4.1. Matriz de correlación de las características derivadas

En los resultados se puede observar que, en general, las correlaciones entre métricas son bajas o moderadas, es decir, las métricas no son redundantes y que las tres tareas

aportan información complementaria sobre el comportamiento de los participantes. Las variables de las tareas Stroop y Flanker presentan correlaciones moderadas en la variabilidad temporal, mientras que las métricas de interferencia tienen relaciones débiles entre tareas.

Para el caso de la tarea Sart, se observa una correlación negativa entre el tiempo de reacción y la tasa de error, lo que indica que respuestas más rápidas tienden a asociarse con mayores tasas de error. En conjunto, estos resultados justifican la estandarización de las características y su uso conjunto en el análisis posterior.

Estos resultados sugieren que las métricas aportan información complementaria y justifican su uso conjunto en etapas posteriores.

4.2 Resultados del aprendizaje no supervisado

Con el objetivo de explorar la estructura del conjunto de datos, se utilizaron técnicas de aprendizaje no supervisado en la matriz de características a nivel de participante. Para analizar la variación de la inercia en función de clusters considerados, se aplicó el método del codo, tal y como se muestra en la Figura 4.2.

El análisis no muestra un punto de inflexión claramente definido, sino una disminución progresiva de la inercia a medida que aumenta el número de *clusters*. Sin embargo, para valores bajos de k se observa una pendiente más pronunciada, lo que indica que un número reducido de agrupaciones capta una parte relevante de la estructura de los datos. Se optó por un número reducido de *clusters* para el análisis, priorizando la interpretación de los perfiles frente a maximizar su separación.

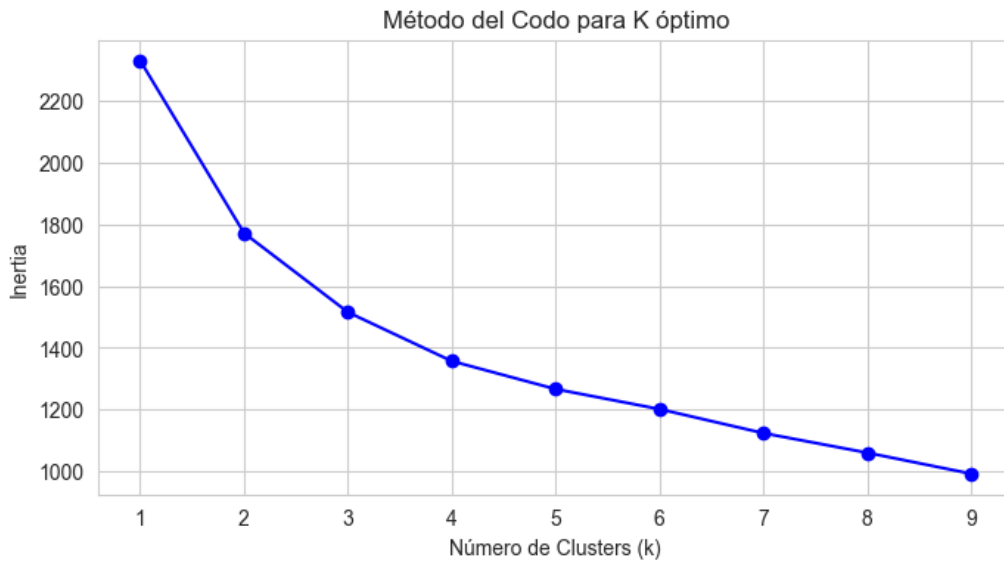


Figura 4.2. Evolución de la inercia en función del número de clusters (método del codo)

Para visualizar la separación entre los perfiles definidos, se empleó una proyección mediante Análisis de Componentes Principales (PCA). En la Figura 4.3 se representa la proyección bidimensional de los participantes, coloreados según el perfil asignado.

La figura muestra una separación parcial entre los perfiles, con un solapamiento considerable entre grupos. Aun así, la diferenciación aparece sobre todo a lo largo de la primera componente principal. Este resultado indica que, aunque los perfiles no forman grupos claramente separables en un espacio de baja dimensión, sí que presentan diferencias para el análisis con modelos supervisados.

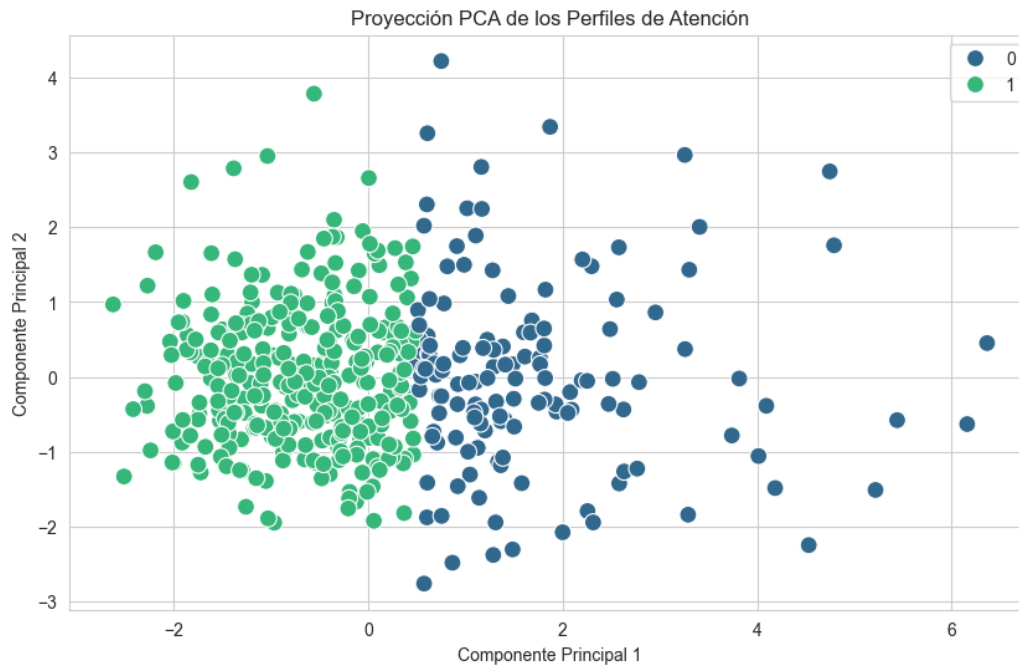


Figura 4.3. Proyección bidimensional mediante Análisis de Componentes Principales (PCA)

4.3 Caracterización de perfiles experimentales

Para el análisis comparativo de los modelos se utilizaron métricas de clasificación y herramientas de visualización. La Figura 4.5 muestra la matriz de confusión del modelo *stacking*, que integra la información de los distintos clasificadores.

La matriz refleja una correcta clasificación de uno de los perfiles experimentales y mayor confusión entre los restantes, tal y como ya se observaba en la fase de aprendizaje no supervisado. Este patrón coincide con el solapamiento visto previamente en el espacio PCA y sugiere que los perfiles presentan fronteras difusas.

Además, se examinó qué variables influyen más en la clasificación mediante valores SHAP (Figura 4.6). Los resultados indican que la discriminación entre perfiles depende de combinaciones de variables y de sus interacciones, más que de umbrales simples sobre características individuales.

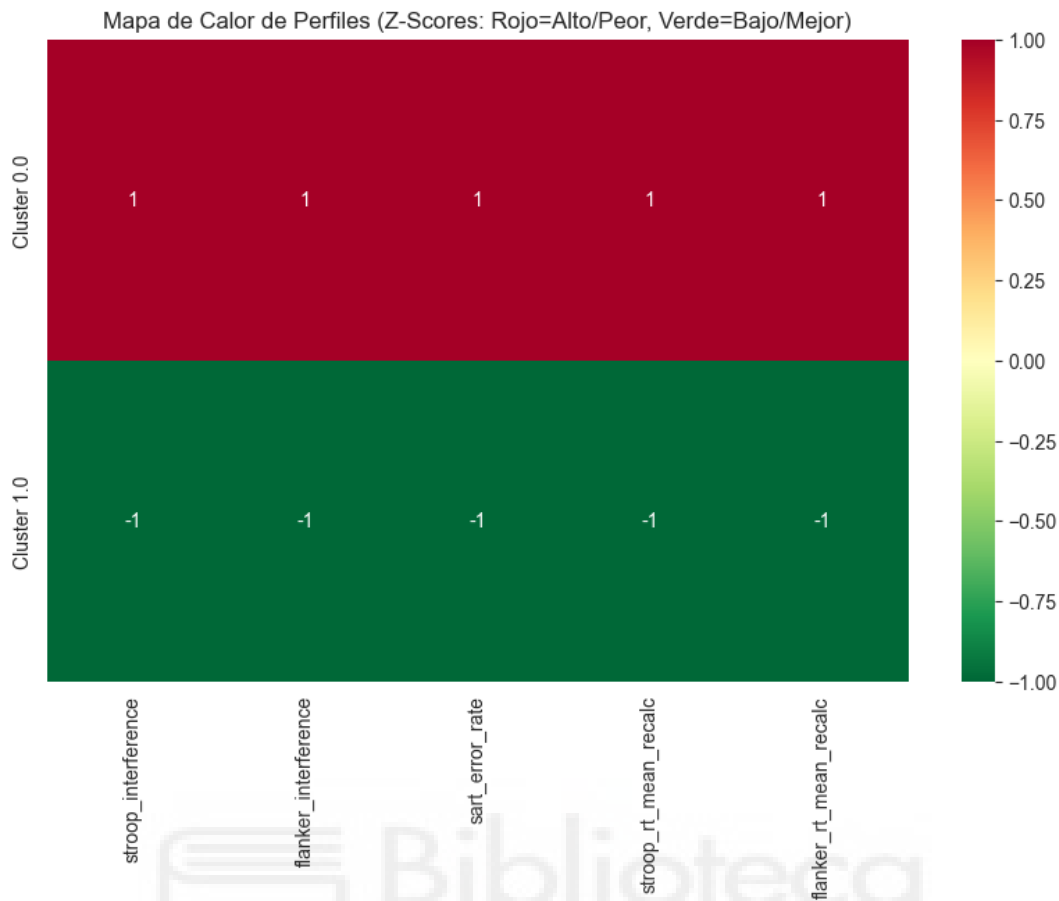


Figura 4.4. Mapa de calor de correlaciones entre características

4.4 Resultados aprendizaje supervisado

Los perfiles experimentales definidos por los modelos de aprendizaje no supervisado se utilizaron como pseudo-etiquetas para entrenar los distintos modelos supervisados. Así se comprobó si los modelos podían distinguir entre las agrupaciones y si los patrones detectados eran coherentes.

Todos los modelos se entrenaron con el mismo conjunto de datos y las mismas pseudo-etiquetas, asegurando así la consistencia del análisis. Después, se evaluó su rendimiento en un conjunto de prueba mediante métricas de clasificación.

Los resultados obtenidos muestran que los distintos modelos tienen un rendimiento similar, con diferencias moderadas en las métricas. Los modelos basados en árboles y ensambles realizan la clasificación de los perfiles de forma más estable, mientras que

otros enfoques aportan información adicional sobre la separabilidad del espacio de características.

En conjunto, los resultados indican que los perfiles definidos mediante el pseudo-etiquetado tienen una estructura suficientemente consistente como para poder ser diferenciada por los distintos modelos.

Que distintos modelos, basados en principios de aprendizaje diferentes, obtengan un rendimiento similar indica que la estructura de los perfiles definidos mediante el pseudo-etiquetado es consistente y no depende de un modelo concreto. Aun así, el rendimiento debe interpretarse teniendo en cuenta que las etiquetas no constituyen un *ground truth*, sino el resultado de un proceso exploratorio.

4.5 Análisis comparativo y visualización de resultados

Para la realización del análisis comparativo de los modelos, se utilizaron métricas de clasificación y herramientas de visualización. En la figura 4.5 se muestra la matriz de confusión del modelo stacking, que integra información procesada por los distintos clasificadores.

La matriz refleja una correcta clasificación de uno de los perfiles experimentales y mayor confusión entre los restantes, tal y como ya se observaba en la fase de aprendizaje no supervisado. Este patrón de confusión es coherente con el solapamiento observado previamente en el espacio PCA, lo que refuerza la interpretación de los perfiles como agrupaciones con fronteras difusas.”

Además, también se examinó qué variables influyen más en la clasificación utilizando valores SHAP (Figura 4.6). Este análisis refuerza la idea de que la clasificación de los perfiles se apoya en combinaciones de variables y sus interacciones, más que en umbrales simples sobre características individuales.”

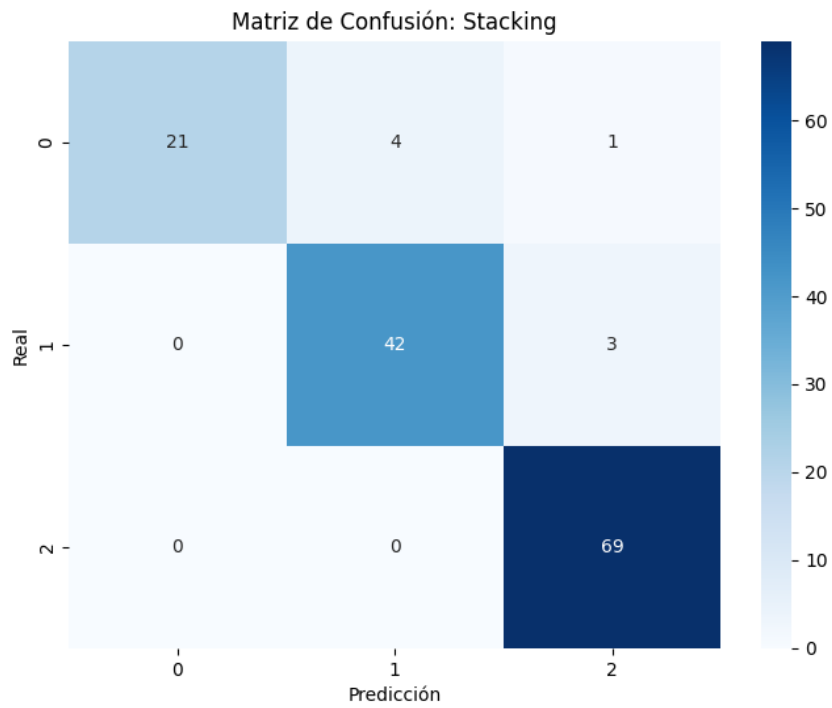


Figura 4.5. Matriz de confusión del modelo Stacking Ensemble

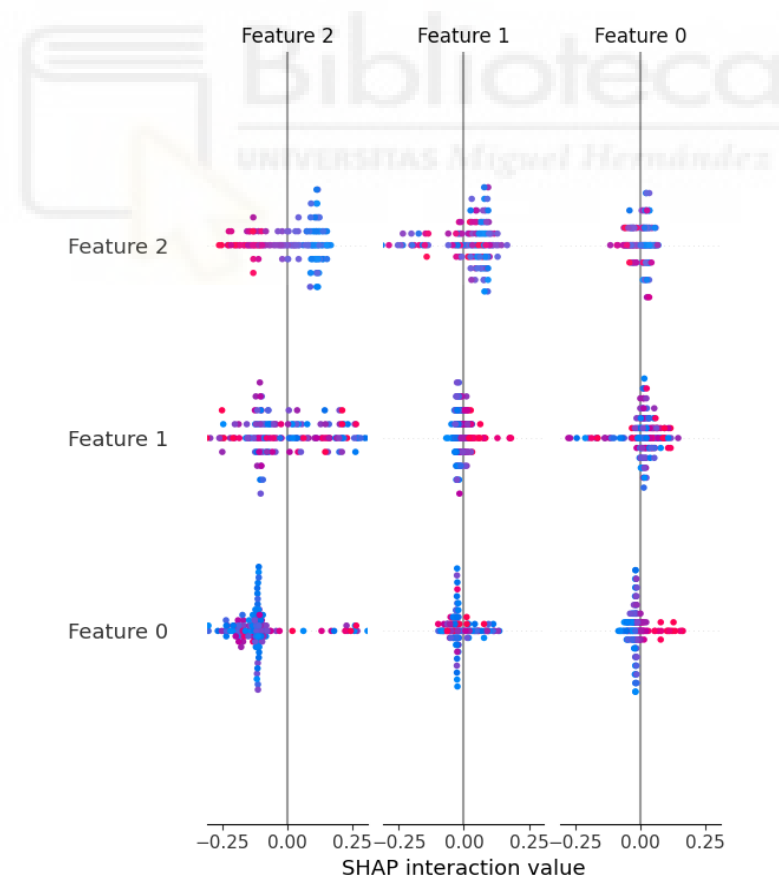


Figura 4.6. Importancia de características mediante valores SHAP

4.6 Síntesis de los resultados

Considerando todos los resultados, el pipeline desarrollado permite transformar los datos obtenidos en las tareas cognitivas en un conjunto de características con el que explorar la organización del comportamiento. Las técnicas de aprendizaje no supervisado identifican agrupaciones coherentes y, por su parte, los modelos supervisados muestran capacidad para diferenciar entre dichos patrones.

Estos resultados deben interpretarse dentro del carácter exploratorio del estudio y según las particularidades del conjunto de datos utilizado. Desde el punto de vista técnico, el sistema evidencia que las técnicas de aprendizaje automático pueden aplicarse al análisis de métricas conductuales.



CAPÍTULO 5. CONCLUSIONES Y TRABAJO FUTURO

5.1 Conclusiones

En este trabajo se ha desarrollado un sistema de análisis basado en técnicas de aprendizaje automático aplicado a métricas conductuales obtenidas a partir de tareas cognitivas digitales. El objetivo principal no ha sido identificar categorías cognitivas o diagnósticas, sino diseñar e implementar un pipeline de procesamiento capaz de transformar registros experimentales a nivel de ensayo en una representación adecuada para su análisis automático.

Durante su desarrollo, se ha comprobado que es posible integrar información procedente de distintas tareas cognitivas en un conjunto común de características, manteniendo coherencia metódica y una separación entre las fases de procesamiento. El análisis exploratorio muestra que las métricas no son altamente redundantes y que cada una de las tareas aportan información diferente sobre el comportamiento de los participantes, lo que justifica su uso conjunto en el sistema.

Con las técnicas de aprendizaje no supervisado se ha explorado la estructura del espacio de características y definir perfiles experimentales basados únicamente en la similitud conductual observada. Estos perfiles, entendidos como agrupaciones empíricas, sirvieron como base para la aplicación de los modelos supervisados en un contexto de pseudo-etiquetado. Los resultados presentan una estructura suficientemente consistente como para ser diferenciados por distintos modelos.

Este enfoque no pretende maximizar el rendimiento de los modelos, sino facilitar una interpretación de los patrones observados. Esta decisión permite analizar el comportamiento de los perfiles de forma controlada, aún a costa de no utilizar modelos más complejos.

Uno de los aspectos más relevantes, está en el diseño modular, reproducible y extensible del sistema, que facilita la reutilización del código y una adaptación del pipeline a nuevos conjuntos de datos o experimentos. El enfoque que se ha adaptado muestra que es posible aplicar técnicas de aprendizaje automático al análisis de datos conductuales mientras se mantenga un marco metodológico y esté acorde con las limitaciones del conjunto de datos.

5.2 Limitaciones del estudio

Este trabajo presenta varias limitaciones que deben considerarse al interpretar los resultados. En primer lugar, el conjunto de datos no dispone de etiquetas clínicas, diagnósticas o categóricas reales, lo que ha llevado a utilizar un enfoque exploratorio basado en pseudo-etiquetado. Esto reduce el alcance de las conclusiones y limita la interpretación de los perfiles a un contexto puramente empírico.

Además, el análisis se ha realizado sobre un conjunto concreto de tareas cognitivas y sobre métricas derivadas de ellas. Aunque estas métricas capturan distintos aspectos del comportamiento atencional, no representan toda su complejidad. Por otro lado, tanto el tamaño como la composición del conjunto de datos pueden influir en la estructura de los perfiles obtenidos y en el rendimiento de los modelos entrenados.

5.3 Líneas de trabajo futuro

A partir de este trabajo se plantean varias líneas futuras. Incorporar nuevos conjuntos de datos o tareas cognitivas permitiría comprobar si el pipeline se mantiene estable en otros contextos y ampliar las métricas analizadas.

También sería útil contar con etiquetas externas (clínicas, experimentales o de otras evaluaciones) para poder validar los perfiles obtenidos. Con esa información se podría realizar un análisis supervisado más completo y evaluar el sistema en situaciones aplicadas.

A nivel técnico, podrían explorarse mejoras como optimizar la selección de características, probar otros métodos de agrupamiento o incorporar técnicas más avanzadas de interpretabilidad. Además, el sistema podría adaptarse a entornos interactivos o a aplicaciones de análisis continuo de datos conductuales. Su diseño modular permite la integración del procesamiento y el análisis de patrones conforme se generan los datos, facilitando una evaluación más dinámica del comportamiento.

Bibliografia

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Wadsworth.
- Broadbent, D. E. (1958). *Perception and communication*. Pergamon Press.
- Corbetta, M., & Shulman, G. L. (2002). Control of goal-directed and stimulus-driven attention. *Nature Reviews Neuroscience*, 3(3), 201–215.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297.
- Desimone, R., & Duncan, J. (1995). Neural mechanisms of selective visual attention. *Annual Review of Neuroscience*, 18, 193–222.
- Deutsch, J. A., & Deutsch, D. (1963). Attention: Some theoretical considerations. *Psychological Review*, 70(1), 80–90.
- Eriksen, B. A., & Eriksen, C. W. (1974). Effects of noise letters upon the identification of a target letter. *Perception & Psychophysics*, 16(1), 143–149.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232.
- Kahneman, D. (1973). *Attention and effort*. Prentice-Hall.
- Lappin, J. S., & Eriksen, C. W. (1966). Use of a delayed signal to stop a visual reaction-time response. *Journal of Experimental Psychology*, 72(6), 805–811.
- Logan, G. D., & Cowan, W. B. (1984). On the ability to inhibit thought and action. *Psychological Review*, 91(3), 295–327.
- Parasuraman, R. (1998). *The attentive brain*. MIT Press.
- Petersen, S. E., & Posner, M. I. (2012). The attention system of the human brain: 20 years after. *Annual Review of Neuroscience*, 35, 73–89.
- Posner, M. I., & Petersen, S. E. (1990). The attention system of the human brain. *Annual Review of Neuroscience*, 13, 25–42.
- Stroop, J. R. (1935). Studies of interference in serial verbal reactions. *Journal of Experimental Psychology*, 18(6), 643–662.
- Treisman, A. (1964). Selective attention in man. *British Medical Bulletin*, 20(1), 12–16.

Wolpert, D. H. (1992). Stacked generalization. *Neural Networks*, 5(2), 241–259.

