


UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE

ESCUELA POLITÉCNICA SUPERIOR DE ELCHE

GRADO EN INGENIERÍA INFORMÁTICA EN
TECNOLOGÍAS DE LA INFORMACIÓN



"SISTEMA DE APOYO AL DIAGNÓSTICO DE
DIABETES Y RETINOPATÍA DIABÉTICA
MEDIANTE TÉCNICAS DE INTELIGENCIA
ARTIFICIAL"

TRABAJO FIN DE GRADO

Febrero–2026

AUTOR: Carmen Navarro Cantó

DIRECTOR/ES: Antonio Peñalver Benavent

Agradecimientos

En primer lugar, me gustaría expresar mi más sincero agradecimiento a mis profesores de la Universidad Miguel Hernández por los conocimientos transmitidos durante estos años, y en especial a mi tutor, Antonio Peñalver Benavent, por su guía, paciencia y consejos fundamentales para el desarrollo de este trabajo.

A mis compañeros y a los amigos que he hecho en la universidad. Me llevo experiencias inolvidables y amistades verdaderas que espero conservar para toda la vida. El camino no ha sido fácil; ha habido momentos muy duros y de mucha presión, pero gracias al apoyo mutuo, las horas de estudio compartidas y los ánimos, hemos logrado superarlos y llegar juntos hasta el final.

A mis amigas, por saber escucharme siempre, por sacarme una sonrisa cuando más lo necesitaba y por apoyarme de forma incondicional en cada paso que doy, dentro y fuera del ámbito académico.

Y, sobre todo, a mis padres. Gracias por vuestro esfuerzo incansable, por creer en mí desde el primer día y por ser mi mayor pilar de fuerza y tranquilidad durante todo este proceso. Sin vuestro apoyo, sacrificio y amor incondicional, este logro no habría sido posible. Este trabajo va por vosotros.

Resumen

Este Trabajo Fin de Grado presenta el desarrollo de un sistema inteligente de apoyo a la decisión clínica para el diagnóstico temprano de la diabetes y la retinopatía diabética mediante técnicas de Inteligencia Artificial. La solución propuesta se estructura en dos módulos predictivos basados en Deep Learning: una Red Neuronal Multicapa (MLP) diseñada para analizar datos clínicos tabulares (optimizada mediante técnicas de balanceo SMOTE) y una Red Neuronal Convolutiva (CNN) orientada a la detección de patrones patológicos directamente en imágenes médicas de fondo de ojo.

Ambos modelos predictivos se han integrado de forma exitosa en una interfaz web interactiva desarrollada con Streamlit. Esta herramienta permite a los profesionales sanitarios realizar evaluaciones individuales, procesar historiales clínicos de forma masiva (vía CSV) y analizar retinografías de manera automatizada. Los resultados obtenidos confirman la alta precisión del sistema, validando su utilidad como herramienta de apoyo para optimizar y agilizar el cribado médico.



Índice

Contenido

CAPÍTULO 1: INTRODUCCIÓN	11
1.1 ¿Qué es la Inteligencia Artificial?	12
1.1.1 Definición	12
1.1.2 Evolución de la IA	13
1.1.3 Aplicaciones generales de la IA en distintos sectores	13
1.1.4 Importancia de la IA en medicina	14
1.2 Contexto y Motivación	16
1.2.1 ¿Qué es la diabetes?.....	16
1.2.2 ¿Qué es la retinopatía diabética?	18
1.2.3 Importancia del diagnóstico temprano de la diabetes.....	21
1.2.4 Impacto de la retinopatía diabética en pacientes diabéticos	22
1.2.5 Cómo la IA puede mejorar el diagnóstico y seguimiento	22
1.3 Redes neuronales y Redes Neuronales Convolucionales	24
1.3.1 Redes Neuronales Artificiales (Artificial Neural Networks, ANN).....	24
1.3.2 Redes convolucionales (Convolutional Neural Networks, CNN).....	25
1.3.3 Diferencias entre ANN y CNN en el contexto del diagnóstico médico .	26
CAPÍTULO 2: ESTADO DE LA CUESTIÓN	28
2.1 Aplicación de la IA en el diagnóstico médico	29
2.1.1 Uso de la IA en la medicina.....	29
2.1.2 Modelos de Machine Learning y Deep Learning aplicados al diagnóstico	30
2.2 Diagnóstico de diabetes con datos numéricos	32
2.2.1 Estudios previos en predicción de diabetes con Machine Learning.....	32
2.2.2 Comparación de técnicas utilizadas en el diagnóstico de la diabetes.....	33
2.3 Diagnóstico de retinopatía diabética con imágenes	34
2.3.1 Uso de las redes convolucionales en la detección de enfermedades	34
oculares	34
CAPÍTULO 3: OBJETIVOS	36
3.1 Objetivo General	37
3.2 Objetivos Específicos	37
3.2.1 Construir un modelo de IA para predecir diabetes a partir de datos	37
numéricos	37
3.2.2 Entrenar una red neuronal convolucional para detectar retinopatía	38
diabética en imágenes de retina	38

3.2.3	Diseñar una interfaz que permita a los usuarios subir sus datos y obtener un diagnóstico preliminar	39
CAPÍTULO 4: HIPÓTESIS DEL TRABAJO.....		40
4.1	Red neuronal para la predicción de diabetes	41
4.1.1	Lenguaje	41
4.1.2	Entorno de desarrollo.....	42
4.1.3	NumPy	42
4.1.4	Pandas.....	43
4.1.5	Scikit-learn	43
4.1.6	Joblib	44
4.1.7	Matplotlib	44
4.2	Red convolucional para la detección de retinopatía diabética.....	45
4.2.1	Entorno de desarrollo.....	45
CAPÍTULO 5: METODOLOGÍA Y RESULTADOS		46
5.1	Planificación del proyecto	47
5.1.1	Desglose de tareas (WBS).....	47
5.1.2	Diagrama de Gantt.....	49
5.2	Desarrollo red neuronal	50
5.2.1	Dataset para la predicción de diabetes.....	50
5.2.2	Métricas de evaluación del modelo	51
5.2.3	Preprocesamiento de los datos.....	53
5.2.4	Arquitectura de la red neuronal	54
5.2.5	Entrenamiento del modelo.....	54
5.3	Desarrollo de la red convolucional.....	60
5.3.1	Preparación del conjunto de datos para la CNN.....	60
5.3.2	Arquitectura de la red convolucional.....	61
5.3.3	Proceso de entrenamiento y ajustes	61
5.3.4	Integración del modelo en la aplicación	62
5.4	Resultados de la red convolucional	62
5.4.1	Comportamiento durante el entrenamiento	62
5.4.2	Métricas globales de rendimiento.....	63
5.4.3	Matriz de confusión e interpretación	63
5.4.4	Validación cualitativa mediante probabilidades.....	64
5.4.5	Limitaciones de la evaluación	64
5.5	Conclusiones parciales sobre el modelo de detección de retinopatía diabética..	65
5.6	Desarrollo de la interfaz gráfica	66
5.6.1	Módulo de predicción de diabetes	66

5.6.2	Módulo de detección de retinopatía.....	72
CAPÍTULO 6: CONCLUSIONES Y TRABAJOS FUTUROS		75
6.1	Conclusiones.....	76
6.2	Líneas de trabajo futuras.....	76
..... CAPÍTULO 7: BIBLIOGRAFÍA		
.....		78



Índice ilustraciones

Ilustración 1 Representación conceptual de la inteligencia artificial	12
Ilustración 2 Principales aplicaciones de la inteligencia artificial en distintos sectores	14
Ilustración 3 Aplicación de la inteligencia artificial en el ámbito de la medicina.....	16
Ilustración 4 Esquema del mecanismo fisiopatológico de la diabetes tipo 1, donde la falta de producción de insulina impide la entrada de glucosa en las células.....	17
Ilustración 5 Esquema del mecanismo fisiopatológico de la diabetes tipo 2, caracterizado por la resistencia a la insulina y la dificultad de la glucosa para entrar en las células.....	18
Ilustración 6 Imagen de fondo de ojo con signos de retinopatía diabética.....	20
Ilustración 7 Flujo de apoyo al diagnóstico médico mediante inteligencia artificial.	23
Ilustración 8 Estructura básica de una red neuronal artificial.	25
Ilustración 9 Arquitectura general de una red neuronal convolucional.....	26
Ilustración 10 Logotipo de Anaconda.	42
Ilustración 11 Logotipo de Numpy.....	43
Ilustración 12 Logotipo de pandas.....	43
Ilustración 13 Logotipo de Scikit- Learn.....	44
Ilustración 14 Logotipo de JobLib.....	44
Ilustración 15 Logotipo de Matplotlib.....	45
Ilustración 16 Desglose de tareas correspondientes a la fase de investigación del proyecto, con su esfuerzo estimado y dependencias.	47
Ilustración 17 Desglose de tareas de la fase de desarrollo del proyecto, detallando las actividades de implementación, entrenamiento de modelos e integración, junto con el esfuerzo estimado.	48
Ilustración 18 Desglose de tareas de la fase de diseño del proyecto, incluyendo la definición de arquitecturas y del flujo de la aplicación, con su esfuerzo estimado.....	48
Ilustración 19 Desglose de tareas de la fase de documentación del proyecto, indicando el esfuerzo total dedicado a la redacción de la memoria final.....	48
Ilustración 20 Diagrama de Gantt del proyecto, donde se representa la planificación temporal de las distintas fases y tareas a lo largo del desarrollo del trabajo.	49
Ilustración 21 Matriz de confusión del modelo mejorado	52
Ilustración 22 Matriz de confusión primer entrenamiento	55
Ilustración 23 Matriz confusión segundo entrenamiento	57
Ilustración 24 Matriz de confusión tercer entrenamiento.....	58
Ilustración 25 Matriz de confusión dataset extendido	59
Ilustración 26 Matriz de confusión CNN binaria	64
Ilustración 27 Vista general de la interfaz de usuario desarrollada con Streamlit. Fuente: Elaboración propia.....	67
Ilustración 28 Detalle de los componentes de selección categórica en el formulario. Fuente: Elaboración propia.....	68
Ilustración 29 Detalle de los componentes de validación de rangos en el formulario. Fuente: Elaboración propia.....	68
Ilustración 30 Detalle de los indicadores binarios de comorbilidad. Fuente: Elaboración propia.....	69
Ilustración 31 Validación del sistema de alertas con un caso positivo simulado. Fuente: Elaboración propia.....	70
Ilustración 32 Módulo de carga masiva de datos en formato CSV. Fuente: Elaboración propia.	71

Ilustración 33 Tabla de resultados del procesamiento por lotes. Fuente: Elaboración propia.	72
Ilustración 34 Interfaz del módulo de diagnóstico por imagen para detección de retinopatía diabética. Fuente: Elaboración propia.	73
Ilustración 35 Validación del módulo de detección de retinopatía diabética con un caso positivo. Fuente: Elaboración propia.	74



CAPÍTULO 1: INTRO- DUCCIÓN



1.1 ¿Qué es la Inteligencia Artificial?

1.1.1 Definición

La inteligencia artificial (IA) es una disciplina de la informática que busca desarrollar sistemas capaces de realizar tareas que tradicionalmente requieren inteligencia humana, como el aprendizaje, la percepción, la toma de decisiones y la resolución de problemas. Su desarrollo ha permitido la automatización de procesos complejos, optimizando la eficiencia en distintos sectores y facilitando el análisis de grandes volúmenes de datos [1].

La IA puede dividirse en distintos niveles según su capacidad de aprendizaje y adaptación:

- IA Débil o Estrecha: Sistemas diseñados para realizar tareas específicas, como asistentes virtuales o reconocimiento de imágenes [2].
- IA Fuerte o General: Una IA capaz de igualar la inteligencia humana en múltiples ámbitos [2].
- IA Superinteligente: Un concepto teórico de una IA que superaría la inteligencia humana en todos los aspectos [2].

En la actualidad, la IA es una de las tecnologías más disruptivas, con un impacto significativo en sectores como la salud, la educación, la industria y la seguridad.



Ilustración 1 Representación conceptual de la inteligencia artificial

1.1.2 Evolución de la IA

El concepto de inteligencia artificial ha evolucionado desde sus primeros desarrollos en los años 50 hasta convertirse en una de las áreas más avanzadas de la computación moderna.

El término “inteligencia artificial” fue acuñado por John McCarthy en 1956 durante la Conferencia de Dartmouth. Sin embargo, las bases de la IA se establecieron décadas antes, con los trabajos de Norbert Wiener y John Von Neumann en teoría de sistemas y computación. A partir de entonces, la IA ha pasado por distintas etapas de desarrollo:

- Décadas de 1950-1970: Primeros avances
 - Desarrollo de los primeros algoritmos de búsqueda y resolución de problemas.
 - Creación de los primeros sistemas expertos en medicina y lógica computacional [2].
- Década de 1980-1990: Auge de los sistemas expertos
 - Creación de programas capaces de tomar decisiones basadas en reglas lógicas.
 - Avances en redes neuronales artificiales inspiradas en el cerebro humano [2].
- Década de 2000-2010: Aprendizaje Automático
 - Popularización del Machine Learning y aumento del poder computacional.
 - IA aplicada en motores de búsqueda, reconocimiento facial y procesamiento del lenguaje natural [2].
- Década de 2010 – Presente: Deep Learning y redes neuronales avanzadas
 - Avances en Deep Learning permiten la aplicación masiva de la IA en imágenes, medicina y finanzas.
 - Redes neuronales convolucionales (CNN) revolucionan el análisis de imágenes médicas.
 - Expansión de la IA en la toma de decisiones clínicas y en la personalización de tratamientos [2].

Hoy en día, la IA sigue evolucionando con modelos cada vez más avanzados, como los sistemas generativos de inteligencia artificial y las aplicaciones en medicina, robótica y automatización industrial.

1.1.3 Aplicaciones generales de la IA en distintos sectores

La inteligencia artificial ha transformado múltiples industrias, permitiendo el desarrollo de sistemas más eficientes y precisos. Algunas de sus aplicaciones más relevantes incluyen [2]:

- Salud y medicina:

- Diagnóstico asistido por IA a partir de imágenes médicas.
- Predicción en enfermedades y personalización de tratamientos.
- Descubrimiento de nuevos fármacos y optimización de ensayos clínicos.
- Industria y manufactura:
 - Robots autónomos en fábricas para ensamblaje y control de calidad.
 - Optimización de la cadena de suministro y logística mediante IA.
- Finanzas y banca:
 - Detección de fraudes en transacciones bancarias.
 - Análisis de riesgos y algoritmos de inversión basados en IA.
- Transporte y automoción:
 - Vehículos autónomos con sistemas de IA para navegación y seguridad.
 - Optimización de rutas en transporte público y logística.
- Educación:
 - Plataformas de aprendizaje personalizadas con IA adaptativa.
 - Evaluación automática de exámenes y generación de material educativo.
- Ciberseguridad:
 - Detección de ataques cibernéticos y prevención de fraudes en redes.
 - Monitoreo en tiempo real de amenazas digitales.

Gracias a estos avances, la IA ha optimizado la eficiencia en múltiples sectores, mejorando la toma de decisiones y facilitando el análisis de datos en tiempo real.



Ilustración 2 Principales aplicaciones de la inteligencia artificial en distintos sectores

1.1.4 Importancia de la IA en medicina

En el ámbito de la salud, la inteligencia artificial ha permitido grandes avances en diagnóstico, tratamiento y gestión hospitalaria. Su capacidad para analizar datos

médicos con rapidez y precisión ha llevado a la creación de herramientas que ayudan a los profesionales de la salud a tomar mejores decisiones. Algunas de sus principales aplicaciones incluyen [3]:

- Diagnóstico asistido por IA:
 - Algoritmos de Deep Learning pueden analizar imágenes médicas y detectar signos tempranos de enfermedades como cáncer, neumonía y retinopatía diabética.
 - Las redes neuronales convolucionales (CNN) han demostrado ser altamente eficaces en la detección de anomalías en radiografías y tomografías.
- Predicción y prevención de enfermedades:
 - Modelos de Machine Learning pueden analizar datos clínicos y predecir la probabilidad de que un paciente desarrolle diabetes o enfermedades cardiovasculares.
 - La IA permite alertar a los médicos sobre patrones anómalos en los datos de los pacientes, mejorando la prevención de enfermedades [4].
- Personalización de tratamientos:
 - La IA permite analizar el perfil genético de un paciente y recomendar terapias específicas, optimizando la efectividad del tratamiento.
 - Se pueden identificar combinaciones de medicamentos más efectivas para cada paciente, reduciendo el riesgo de efectos secundarios.
- Automatización de procesos hospitalarios:
 - La IA facilita la gestión de registros médicos electrónicos, optimizando la organización de la información.
 - Chatbots médicos pueden responder preguntas frecuentes y ayudar en la gestión de citas y seguimientos.
- Investigación y desarrollo de fármacos:
 - Algoritmos de IA han acelerado el proceso de descubrimiento de nuevos medicamentos.
 - Se han desarrollado simulaciones computacionales para predecir la efectividad de nuevas moléculas en el tratamiento. La inteligencia artificial (IA) está revolucionando la medicina al proporcionar herramientas avanzadas para mejorar la precisión de los diagnósticos, personalizar tratamientos y optimizar la gestión hospitalaria de enfermedades.



Ilustración 3 Aplicación de la inteligencia artificial en el ámbito de la medicina

En el caso particular de la diabetes, la IA juega un papel clave en la detección temprana y seguimiento de la enfermedad. Modelos de Machine Learning han sido entrenados para analizar datos de análisis de sangre y predecir si un paciente es diabético o tiene riesgo de desarrollarla. Por otro lado, en la retinopatía diabética, las redes convolucionales han demostrado ser efectivas en la detección de anomalías en imágenes de fondo de ojo, permitiendo una identificación más rápida y precisa de la enfermedad.

El uso de IA en medicina no solo mejora la precisión en los diagnósticos, sino que también permite una atención médica más personalizada y accesible, optimizando los recursos disponibles en los sistemas de salud.

1.2 Contexto y Motivación

1.2.1 ¿Qué es la diabetes?

La diabetes es una enfermedad crónica que afecta la capacidad del cuerpo para regular los niveles de glucosa en sangre. Esta alteración puede deberse a una producción insuficiente de insulina por parte del páncreas o a una resistencia de las células a la acción de esta hormona. Existen distintos tipos de diabetes, cada uno con causas y factores de riesgo específicos [5].

Diabetes tipo 1

La diabetes tipo 1 es una enfermedad autoinmune en la que el sistema inmunológico ataca por error a las células beta del páncreas, encargadas de producir insulina. Como resultado, el cuerpo deja de producir esta hormona, lo que provoca un aumento incontrolado de la glucosa en sangre [6].

Los factores de riesgo para la diabetes tipo 1 incluyen:

- Antecedentes familiares: Tener un padre o un hermano con diabetes tipo 1 aumenta el riesgo de desarrollar la enfermedad.
- Edad: Aunque puede aparecer a cualquier edad, es más común en niños, adolescentes y adultos jóvenes.
- Factores genéticos y ambientales: Aunque no se conoce una causa exacta, se han identificado ciertos genes asociados con un mayor riesgo, y se sospecha que factores ambientales pueden influir en su desarrollo.



Ilustración 4 Esquema del mecanismo fisiopatológico de la diabetes tipo 1, donde la falta de producción de insulina impide la entrada de glucosa en las células.

Diabetes tipo 2

La diabetes tipo 2 es la forma más frecuente de la enfermedad y se caracteriza por la resistencia a la insulina y la insuficiente producción de esta hormona. A diferencia de la diabetes tipo 1, la diabetes tipo 2 puede prevenirse o retrasarse mediante cambios en el estilo de vida [6].

Factores de riesgo para la diabetes tipo 2:

- Sobrepeso u obesidad: El exceso de grasa, especialmente en la zona abdominal, aumenta la resistencia a la insulina.
- Falta de actividad física: Un estilo de vida sedentario contribuye a la obesidad y dificulta el uso eficiente de la glucosa en las células.
- Antecedentes familiares: Tener un familiar de primer grado con diabetes tipo 2 incrementa el riesgo de padecer la enfermedad.
- Edad: Aunque puede afectar a personas de cualquier edad, la diabetes tipo 2 es más común a partir de los 45 años.
- Diabetes gestacional previa: Haber tenido diabetes durante el embarazo aumenta el riesgo de desarrollar diabetes tipo 2 en el futuro.
- Hipertensión y niveles elevados de triglicéridos: Estos factores aumentan la probabilidad de desarrollar resistencia a la insulina.



Ilustración 5 Esquema del mecanismo fisiopatológico de la diabetes tipo 2, caracterizado por la resistencia a la insulina y la dificultad de la glucosa para entrar en las células.

Diabetes gestacional

Es un tipo de diabetes que aparece durante el embarazo debido a los cambios hormonales que afectan la acción de la insulina. Aunque suele desaparecer tras el parto, aumenta el riesgo de desarrollar diabetes tipo 2 en el futuro, tanto en la madre como en el hijo [6].

Factores de riesgo para la diabetes gestacional:

- Sobrepeso u obesidad antes del embarazo
- Antecedentes familiares de diabetes tipo 2
- Edad mayor a 25 años
- Síndrome del ovario poliquístico (PCOS)
- Pertenencia a determinados grupos étnicos, como afroamericanos, hispanos, indígenas americanos y asiáticos.

Si no se trata adecuadamente, la diabetes puede causar complicaciones graves, afectando órganos como el corazón, los riñones, el sistema nervioso y los ojos. Una de las complicaciones más comunes y graves es la retinopatía diabética, una enfermedad ocular que puede causar pérdida de visión irreversible.

1.2.2 ¿Qué es la retinopatía diabética?

La retinopatía diabética es una de las principales causas de ceguera en adultos y se produce debido al daño en los vasos sanguíneos de la retina como consecuencia de niveles elevados y prolongados de glucosa en sangre. La enfermedad progresa en varias etapas y puede afectar tanto a la visión central como la periférica [7].

La retinopatía diabética evoluciona en dos etapas principales:

- Retinopatía diabética no proliferativa (RDNP) [8]
 - Es la fase inicial de la enfermedad y puede pasar desapercibida, ya que en muchos casos no presenta síntomas evidentes.
 - Se caracteriza por la aparición de microaneurismas (pequeñas dilataciones en los vasos sanguíneos), hemorragias retinianas y acumulación de líquido en la retina (edema macular).
 - En algunos casos, los vasos sanguíneos pueden obstruirse, causando isquemia macular, lo que impide la correcta oxigenación de la retina.
- Retinopatía diabética proliferativa (RDP) [8]
 - Es la fase más avanzada de la enfermedad y se produce cuando la retina responde a la falta de oxígeno generando nuevos vasos sanguíneos anormales.
 - Estos vasos son frágiles y tienden a romperse, causando hemorragias vítreas que pueden bloquear la visión.
 - Con el tiempo, el tejido cicatricial puede provocar un desprendimiento de retina, lo que puede llevar a la ceguera total si no se trata a tiempo.

Síntomas de la retinopatía diabética

En las primeras etapas, la retinopatía diabética puede no presentar síntomas. Sin embargo, a medida que la enfermedad progresa, pueden aparecer signos como [8]:

- Visión borrosa
- Aumento en la presencia de “moscas volantes” o manchas oscuras en el campo visual
- Dificultad para ver en la oscuridad
- Zonas de visión en blanco o negras
- Pérdida progresiva de la agudeza visual

Diagnóstico de la retinopatía diabética

El diagnóstico temprano es clave para evitar la progresión de la enfermedad. Las principales pruebas utilizadas para detectar la retinopatía diabética incluyen [8]:

- Examen de fondo de ojo con dilatación pupilar: Permite observar la retina y detectar signos de daño vascular
- Angiografía con fluoresceína: Se inyecta un tinte en la sangre y se toman imágenes para identificar fugas o bloqueos en los vasos sanguíneos de la retina

- Tomografía de coherencia óptica (OCT): Técnica de imagen que permite evaluar el grosor de la retina y detectar acumulación de líquido

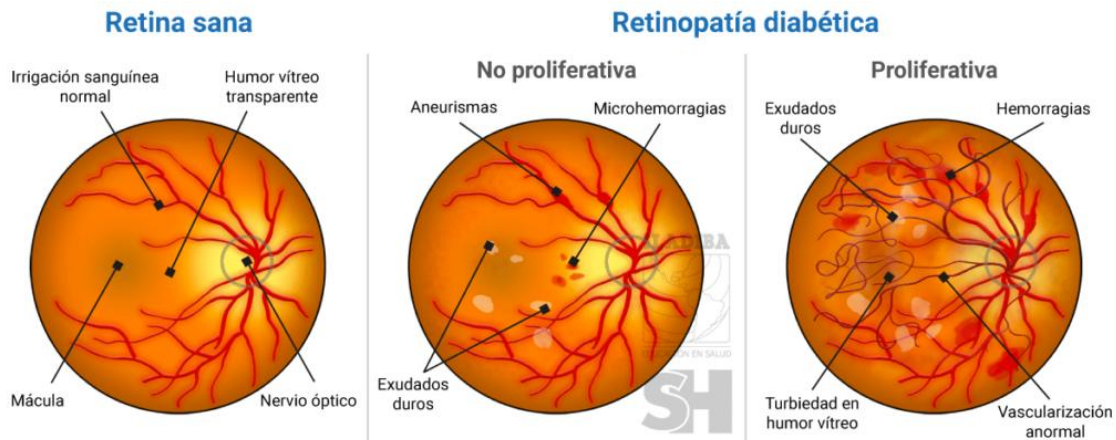


Ilustración 6 Imagen de fondo de ojo con signos de retinopatía diabética.

Tratamiento de la retinopatía diabética

El tratamiento depende del grado de avance de la enfermedad. Algunas opciones incluyen:

- Control de la glucosa y presión arterial: Mantener niveles óptimos de glucosa y presión arterial es fundamental para ralentizar la progresión de la enfermedad
- Terapia anti-VEGF: Inyecciones intravítreas de medicamentos como Avastin, Eylea o Lucentis, que ayudan a reducir el edema macular y prevenir el crecimiento de vasos sanguíneos anormales.
- Fotocoagulación con láser: Se utiliza para sellar vasos sanguíneos con fugas y reducir el crecimiento de nuevos vasos anómalos.
- Vitrectomía: Procedimiento quirúrgico indicado en casos avanzados para eliminar sangre acumulada en el vítreo y tejido cicatricial.

Prevención de la retinopatía diabética

Dado que la retinopatía diabética es una complicación de la diabetes, la mejor forma de prevenirla es mediante un adecuado control de la enfermedad. Algunas medidas preventivas incluyen [8]:

- Controlar periódicamente los niveles de glucosa en sangre
- Mantener la presión arterial y el colesterol dentro de rangos saludables
- Realizar revisiones oftalmológicas anuales

- Llevar un estilo de vida saludable con una dieta equilibrada y ejercicio regular
- Evita el consumo de tabaco, ya que este agrava el daño vascular

1.2.3 Importancia del diagnóstico temprano de la diabetes

La diabetes es una de las enfermedades crónicas más presentes en la población mundial, afectando a millones de personas y representando un desafío creciente para los sistemas de salud. Detectarla en sus primeras etapas es fundamental, ya que permite implementar estrategias de control y tratamiento antes de que aparezcan complicaciones graves [9].

El diagnóstico temprano de la diabetes tiene varios beneficios clave:

- **Prevención de complicaciones:** Un diagnóstico oportuno permite iniciar cambios en el estilo de vida y tratamiento médico que pueden retrasar o prevenir complicaciones como enfermedades cardiovasculares, daño renal y neuropatías.
- **Mejora en la calidad de vida:** Los pacientes diagnosticados a tiempo pueden adoptar medidas para mantener niveles óptimos de glucosa en sangre, reduciendo la progresión de la enfermedad.
- **Reducción de costos en salud:** Detectar la enfermedad en fases iniciales evita hospitalizaciones y tratamientos más complejos, lo que alivia la carga económica tanto para los sistemas de salud como para los pacientes.

A pesar de su importancia, muchas personas desconocen que padecen diabetes hasta que aparecen síntomas avanzados. Por ello, es necesario desarrollar herramientas eficaces y accesibles que permitan una detección temprana, rápida y precisa.

En este contexto, la inteligencia artificial (IA) ha comenzado a desempeñar un papel clave. Gracias al análisis masivo de datos médicos —como los generados por sistemas de monitorización continua de glucosa (MCG), plumas inteligentes o relojes—, los algoritmos de IA pueden detectar patrones, predecir eventos glucémicos y generar alertas ante posibles situaciones de riesgo, como hipoglucemias o hiperglucemias. Esto permite una toma de decisiones más informada y personalizada, tanto para pacientes como para profesionales sanitarios.

A pesar de sus beneficios, la implementación de la IA también presenta desafíos: desde la interpretabilidad de los modelos (frecuentemente considerados "cajas negras") hasta cuestiones éticas y de privacidad sobre el uso de datos personales. Además, es fundamental garantizar que los modelos sean seguros, representativos y libres de sesgos, ya que una mala calidad de los datos podría generar decisiones inapropiadas. No

obstante, con el avance actual de la tecnología, todo apunta a que la IA jugará un papel cada vez más relevante en el diagnóstico temprano y la gestión personalizada de la diabetes.

1.2.4 Impacto de la retinopatía diabética en pacientes diabéticos

La retinopatía diabética es una de las principales complicaciones de la diabetes y una de las principales causas de ceguera en adultos a nivel mundial. Se produce cuando los niveles elevados de glucosa en sangre dañan los vasos sanguíneos de la retina, provocando alteraciones en la visión y, en casos avanzados, pérdida total de la vista.

El impacto de la retinopatía diabética en los pacientes incluye:

- Disminución progresiva de la visión: En sus primeras etapas, la retinopatía puede no presentar síntomas, pero a medida que avanza, la visión se vuelve borrosa y se pueden desarrollar manchas en el campo visual.
- Riesgo de ceguera irreversible: Sin un tratamiento adecuado, la enfermedad puede llevar a la ceguera total debido a desprendimiento de retina o al crecimiento anormal de vasos sanguíneos.
- Limitaciones en la vida diaria: La pérdida de visión afecta a la capacidad de las personas para realizar tareas cotidianas, lo que impacta a su autonomía y calidad de vida.
- Costos médicos elevados: La detección tardía de la retinopatía diabética puede requerir tratamientos costosos como la fotocoagulación con láser, inyecciones intraoculares o cirugía.

Dado que la retinopatía diabética puede desarrollarse sin síntomas evidentes, los exámenes periódicos de fondo de ojo son esenciales para su detección temprana. Aquí es donde la inteligencia artificial puede desempeñar un papel crucial en la identificación rápida y precisa de signos de la enfermedad.

1.2.5 Cómo la IA puede mejorar el diagnóstico y seguimiento

La inteligencia artificial ha demostrado ser una herramienta prometedora en el campo de la medicina, ofreciendo soluciones innovadoras para el diagnóstico y seguimiento de enfermedades como la diabetes y la retinopatía diabética. Sus aplicaciones en este ámbito incluyen [10]:

- Predicción de diabetes con datos numéricos: Algoritmos de Machine Learning pueden analizar múltiples factores de riesgo (edad, IMC, nivel de glucosa en sangre, presión arterial, etc.) y predecir con alta precisión si un paciente tiene probabilidades de

desarrollar diabetes. Esto permite identificar a personas en riesgo antes de que presenten síntomas.

- Detección de retinopatía diabética mediante redes convolucionales: Modelos de Deep Learning, especialmente redes neuronales convolucionales (CNN), pueden analizar imágenes de fondo de ojo y detectar signos tempranos de retinopatía con una precisión comparable a la de un especialista en oftalmología. Esto es especialmente útil en áreas con acceso limitado a médicos especialistas.

- Automatización del diagnóstico y reducción del tiempo de evaluación: Los sistemas de IA pueden procesar grandes volúmenes de datos de manera rápida y eficiente, permitiendo obtener diagnósticos en segundos, lo que facilita la toma de decisiones clínicas y reduce la carga de trabajo de los profesionales de la salud.

- Monitoreo continuo de la salud del paciente: La IA permite el desarrollo de aplicaciones que pueden realizar un seguimiento de los niveles de glucosa, detectar patrones anómalos y alertar al paciente y a su médico en caso de riesgo de complicaciones.

- Mayor accesibilidad al diagnóstico: En regiones con escasez de especialistas, la IA puede ofrecer soluciones portátiles que permitan realizar evaluaciones preliminares y derivar a los pacientes con mayor riesgo a una consulta especializada.

Gracias a estos avances, la inteligencia artificial se perfila como una herramienta clave para mejorar la prevención, detección y manejo de la diabetes y sus complicaciones, proporcionando diagnósticos más rápidos y precisos y optimizando los recursos del sistema de salud [11].




Ilustración 7 Flujo de apoyo al diagnóstico médico mediante inteligencia artificial.

1.3 Redes neuronales y Redes Neuronales Convolucionales

1.3.1 Redes Neuronales Artificiales (Artificial Neural Networks, ANN)

Las redes neuronales artificiales (ANN, por sus siglas en inglés) son un modelo computacional inspirado en el funcionamiento del cerebro humano. Se basan en un conjunto de nodos interconectados llamados neuronas artificiales, que funcionan de manera similar a las neuronas biológicas en el cerebro. Estas redes tienen la capacidad de aprender patrones complejos a partir de datos y se utilizan en diversas aplicaciones, incluyendo el diagnóstico médico [12].

Una ANN está compuesta por diferentes capas:

- **Capa de entrada:** Es la encargada de recibir los datos iniciales. En el caso de diagnóstico médico basado en datos clínicos, esta capa podría recibir valores como la glucosa en sangre, el índice de masa corporal (IMC), la presión arterial, entre otros.
- **Capas ocultas:** Estas capas intermedias procesan la información mediante una combinación de pesos y funciones de activación. Su propósito es extraer relaciones y patrones entre los datos, permitiendo que la red aprenda características complejas.
- **Capa de salida:** Genera la predicción final. En un sistema de diagnóstico de diabetes basado en ANN, la salida podría ser una clasificación binaria (diabético/no diabético) o una probabilidad asociada a la presencia de la enfermedad.

Cada conexión entre neuronas tiene un peso, que determina la importancia de la información que fluye a través de la red. Durante el proceso de entrenamiento, estos pesos se ajustan mediante un algoritmo de aprendizaje, como backpropagation (retropropagación del error), con el objetivo de minimizar la diferencia entre la salida predicha y la real [13].

Las ANN han demostrado ser eficaces en problemas donde los datos no siguen una distribución lineal y pueden detectar correlaciones entre variables que no son evidentes para los humanos. En el ámbito médico, estas redes han sido ampliamente utilizadas para predecir enfermedades basadas en datos clínicos, facilitando diagnósticos más precisos y rápidos.

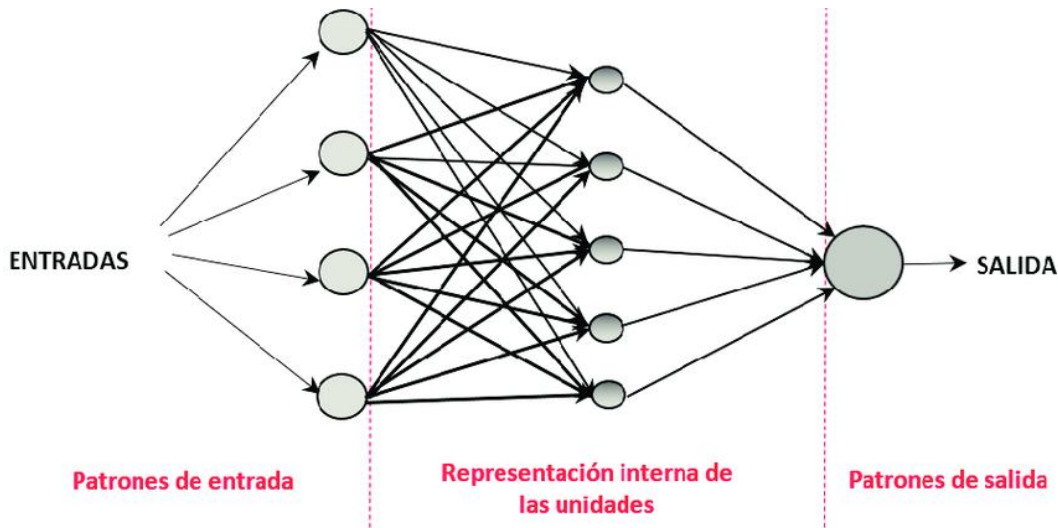


Ilustración 8 Estructura básica de una red neuronal artificial.

1.3.2 Redes convolucionales (Convolutional Neural Networks, CNN)

Las redes neuronales convolucionales (CNN) representan un tipo especializado de ANN, diseñadas específicamente para el procesamiento y análisis de imágenes. Su estructura está inspirada en la organización de la corteza visual del cerebro humano, donde diferentes grupos de neuronas responden a patrones visuales específicos.

A diferencia de las ANN tradicionales, donde cada neurona está conectada con todas las demás de la siguiente capa, las CNN emplean un sistema de convoluciones que permite analizar solo una región de la imagen a la vez, extrayendo características esenciales como bordes, texturas y formas. Esto las hace particularmente útiles en diagnóstico médico por imágenes, ya que pueden analizar radiografías, resonancias magnéticas o fotografías de retina de alta precisión [14].

El funcionamiento de una CNN se basa en varias capas principales:

- **Capas convolucionales:** Son el componente clave de la CNN. Estas capas aplican filtros sobre la imagen para identificar características importantes. Los primeros filtros detectan patrones básicos como bordes y contornos, mientras que las capas más profundas identifican estructuras complejas como lesiones o anomalías [15].
- **Capa de activación (ReLU – Rectified Linear Unit):** Introducen no linealidad en la red para permitir que aprenda patrones complejos.
- **Capas de pooling (Reducción de muestreo):** Reducen la dimensión de las características extraídas sin perder información relevante. Esto hace que el modelo sea más eficiente y robusto frente a variaciones en las imágenes.
- **Capas totalmente conectadas:** Estas capas, similares a las utilizadas en ANN, combinan las características extraídas y generan la predicción final.

En el contexto de diagnóstico de retinopatía diabética, las CNN pueden analizar imágenes de fondo de ojo para identificar signos de la enfermedad, como microaneurismas, hemorragias o exudados. Su capacidad de detectar patrones complejos sin intervención humana permite realizar diagnósticos rápidos y precisos, apoyando a los especialistas en oftalmología [15].




Ilustración 9 Arquitectura general de una red neuronal convolucional.

1.3.3 Diferencias entre ANN y CNN en el contexto del diagnóstico médico

Aunque tanto las ANN como las CNN son utilizadas en inteligencia artificial para el diagnóstico médico, cada una está optimizada para un tipo específico de datos y tareas.

Característica	Redes Neuronales Artificiales (ANN)	Redes Neuronales Convolucionales (CNN)
Tipo de datos	Datos numéricos estructurados (ej. análisis de sangre)	Imágenes médicas (ej. Fondo de ojo, radiografías)
Arquitectura	Capas densamente conectadas entre neuronas	Capas convolucionales especializadas en la detección de características espaciales
Aplicación en medicina	Predicción basada en características tabulares (ej. nivel de glucosa, presión arterial)	Análisis de imágenes médicas para detección de anomalías

Procesamiento	Cada entrada afecta a todas las neuronas de la siguiente capa	Utiliza filtros para detectar patrones espaciales en la imagen
Ventajas	Buena precisión en datos tabulares, fácil de entrenar con menos datos	Alta precisión en imágenes médicas, capacidad de identificar patrones complejos

En el caso del presente trabajo, la ANN se aplicará para predecir la presencia de diabetes a partir de análisis de sangre, utilizando variables como la glucosa en ayunas y el historial médico del paciente. Por otro lado, la CNN se utilizará para detectar retinopatía diabética en imágenes de retina, identificando signos de la enfermedad de manera automatizada.

Esta combinación de enfoques permite abordar la detección de la diabetes desde dos perspectivas complementarias: el análisis de datos clínicos y el diagnóstico por imágenes, proporcionando un sistema de apoyo a los profesionales de la salud en la detección temprana de la enfermedad y sus complicaciones.



CAPÍTULO 2: ESTADO DE LA CUESTIÓN

2.1 Aplicación de la IA en el diagnóstico médico

2.1.1 Uso de la IA en la medicina

La inteligencia artificial (IA) está revolucionando la medicina al proporcionar herramientas avanzadas para mejorar la precisión de los diagnósticos, personalizar tratamientos y optimizar la gestión hospitalaria. Su capacidad para analizar grandes volúmenes de datos permite detectar patrones y correlaciones que pueden ser difíciles de identificar por los profesionales de la salud [16].

Actualmente, las principales aplicaciones de la IA en la medicina incluyen [17]:

- **Apoyo a la toma de decisiones clínicas:** Los sistemas de IA analizan registros médicos, estudios científicos y datos en tiempo real para ayudar a los médicos en la elección de tratamientos y diagnósticos más acertados. Estos sistemas pueden reducir errores y mejorar la calidad asistencial al proporcionar información basada en evidencia.
- **Análisis de imágenes médicas:** Las redes neuronales convolucionales (CNN) se han utilizado con éxito en el análisis de radiografías, tomografías computarizadas y resonancias magnéticas. Estas herramientas pueden detectar signos tempranos de enfermedades como el cáncer, la retinopatía diabética y patologías pulmonares con una precisión comparable a la de los radiólogos humanos.
- **Monitoreo de pacientes:** La IA permite analizar datos en tiempo real provenientes de sensores y dispositivos médicos, alertando a los profesionales de la salud ante cambios críticos en los signos vitales de un paciente, como la detección temprana de sepsis o insuficiencia cardíaca.
- **Optimización de ensayos clínicos:** La IA agiliza la identificación de candidatos para ensayos clínicos y permite analizar grandes volúmenes de datos para evaluar la eficacia de tratamientos, acelerando el proceso de desarrollo de fármacos.
- **Medicina personalizada:** Gracias al análisis de datos genéticos y clínicos, los algoritmos de IA pueden predecir cómo responderá un paciente a un tratamiento específico, facilitando la personalización de la atención médica y reduciendo efectos adversos.

2.1.2 Modelos de Machine Learning y Deep Learning aplicados al diagnóstico

El uso de modelos de Machine Learning (ML) y Deep Learning (DL) ha sido clave en la transformación del diagnóstico médico. Estos algoritmos pueden identificar patrones en grandes volúmenes de datos y mejorar su precisión con el tiempo, lo que ha llevado a avances significativos en la detección y predicción de enfermedades [18].

Machine Learning en diagnóstico médico

El Machine Learning se basa en algoritmos que aprenden a partir de datos sin necesidad de ser programados explícitamente. Entre las técnicas más utilizadas en el diagnóstico médico destacan [18]:

- **Árboles de decisión y bosques aleatorios:** Se emplean para predecir la probabilidad de enfermedades basándose en múltiples factores de riesgo, como la diabetes o las enfermedades cardiovasculares.
- **Máquinas de soporte vectorial (SVM):** Utilizadas en la clasificación de datos médicos, como la detección de células cancerígenas en biopsias.
- **Redes neuronales artificiales (ANNs):** Se aplican en el análisis de datos clínicos complejos, mejorando la precisión diagnóstica mediante el aprendizaje de patrones en grandes volúmenes de datos.

Uno de los casos más relevantes es el uso de machine learning en la detección del cáncer de mama a través de imágenes de ultrasonido y rayos X. En este tipo de problemas, se emplea el aprendizaje supervisado de clasificación, en el que el algoritmo aprende a etiquetar correctamente imágenes nuevas en función de características previas. Además, estos modelos pueden resaltar las áreas sospechosas en las imágenes médicas, proporcionando información valiosa a los radiólogos para una mejor evaluación.

Otro uso importante de machine learning en salud es la detección del Alzheimer a través del análisis de patrones de habla. Algoritmos de IA analizan pausas entre palabras, pronunciación, frecuencia y amplitud de los sonidos para identificar síntomas tempranos de la enfermedad, facilitando un diagnóstico precoz que puede mejorar la calidad de vida de los pacientes.

Deep Learning en el análisis de imágenes médicas

El Deep Learning, una subcategoría del Machine Learning, ha demostrado ser especialmente eficaz en el análisis de imágenes médicas. Las redes neuronales convolucionales (CNNs) son ampliamente utilizadas en este campo. Algunos ejemplos incluyen [19]:

- **Detección de cáncer:** Modelos basados en CNNs han demostrado ser capaces de detectar tumores en mamografías con una precisión similar o superior a la de los especialistas humanos. Google Health ha desarrollado un sistema de IA capaz de superar los radiólogos en la detección de cáncer de mama.

- **Diagnóstico de enfermedades oculares:** En el caso de la retinopatía diabética, los modelos de IA pueden analizar imágenes de fondo de ojo para identificar signos tempranos de la enfermedad, alcanzando niveles de precisión del 95%. En Chile, la herramienta DART (Detección Automática de Retinopatía Diabética) utiliza CNNs para analizar fotografías del fondo de ojo, logrando un alto nivel de precisión en la detección de anomalías.
- **Identificación de enfermedades pulmonares:** Durante la pandemia de COVID-19, se desarrollaron modelos de IA capaces de analizar radiografías de tórax para identificar signos de infección pulmonar, lo que ayudó a acelerar los diagnósticos en pacientes con complicaciones respiratorias.

IA y el diagnóstico basado en datos clínicos

Además del análisis de imágenes, la IA también se aplica a la evaluación de datos clínicos estructurados, como los resultados de análisis de sangre. Por ejemplo, en el diagnóstico de diabetes, los modelos de machine learning pueden analizar múltiples variables (niveles de glucosa, presión arterial, triglicéridos, etc.) para predecir el riesgo de desarrollar la enfermedad.

Asimismo, durante la pandemia de COVID-19, la IA fue utilizada en la predicción del riesgo de contagio. En China, la aplicación Health Code utilizó modelos de machine learning para analizar información de los ciudadanos, incluyendo síntomas, historial de viajes y contacto con pacientes infectados. Esta herramienta ayudó a controlar la propagación del virus al restringir la movilidad de personas con alto riesgo de infección.

Mitos y desafíos en la aplicación de IA en medicina

A pesar de los avances en IA aplicada al diagnóstico médico, aún existen desafíos y mitos que deben abordarse:

- **“La IA reemplazará a los médicos”:** Aunque la IA es una herramienta poderosa, su objetivo es asistir, no reemplazar, a los profesionales de la salud. Los modelos de IA pueden ayudar en la detección de enfermedades, pero la interpretación clínica y el tratamiento siguen siendo responsabilidad de los médicos [20].
- **“Más datos y mejores científicos de datos garantizan el éxito”:** La calidad de los datos es crucial. Incluso los mejores modelos de machine learning pueden fallar si los datos utilizados no son representativos o tienen sesgos [21].
- **“Los médicos siempre utilizan los modelos de IA más reciente”:** La adopción de modelos de IA en medicina es un proceso lento debido a la necesidad de validación clínica y regulaciones estrictas. Muchos profesionales de la salud continúan utilizando modelos bien establecidos en lugar de adoptar los más recientes de inmediato.

Desafíos y futuro de la IA en el diagnóstico médico

A pesar de los avances logrados, la implementación de IA en el diagnóstico médico enfrenta desafíos como [22]:

- **Disponibilidad y calidad de los datos:** Se requiere una gran cantidad de datos de alta calidad para entrenar modelos precisos.
- **Privacidad y seguridad de los datos:** El acceso a información médica está regulado por normativas estrictas para proteger la privacidad de los pacientes.
- **Sesgo en los datos y equidad en la IA:** Si los datos de entrenamiento no representan adecuadamente a toda la población, los modelos pueden generar sesgos en los diagnósticos.
- **Regulación y validación clínica:** Es fundamental establecer normativas y protocolos para garantizar la seguridad y eficacia de los sistemas de IA en el ámbito médico.

La inteligencia artificial está transformando el diagnóstico médico mediante el uso de Machine Learning y Deep Learning. Su capacidad para analizar grandes volúmenes de datos ha permitido mejorar la precisión y rapidez en la detección de enfermedades, beneficiando tanto a los profesionales de la salud como a los pacientes. Sin embargo, su implementación requiere una regulación adecuada y un enfoque ético para garantizar su efectividad y equidad en la atención médica.

2.2 Diagnóstico de diabetes con datos numéricos

El diagnóstico temprano de la diabetes es crucial para prevenir complicaciones y mejorar la calidad de vida de los pacientes. En este sentido, el uso de modelos de inteligencia artificial ha demostrado ser una herramienta eficaz para analizar datos clínicos y predecir la presencia de la enfermedad con alta precisión. Diversos estudios han explorado el uso de técnicas de Machine Learning en la detección de diabetes, comparando diferentes enfoques y modelos para identificar el más efectivo.

2.2.1 Estudios previos en predicción de diabetes con Machine Learning

A lo largo de los años, se han desarrollado múltiples estudios que aplican algoritmos de Machine Learning para la predicción de la diabetes utilizando conjuntos de datos clínicos. En particular, el uso de datos numéricos extraídos de historiales médicos y análisis bioquímicos ha permitido entrenar modelos con alta capacidad predictiva.

Por ejemplo, un estudio basado en el Sylhet Diabetic Hospital Dataset aplicó modelos de aprendizaje automático para predecir la diabetes en pacientes basándose en 17 variables clínicas y sociodemográficas. Mediante la aplicación de técnicas de preprocesamiento como el sobremuestreo de minorías sintéticas (SMOTE) y la normalización min-max, se logró mejorar la calidad del dataset antes de alimentar los modelos. Los resultados mostraron que los modelos basados en mapas cognitivos

difusos (Fuzzy Cognitive Maps, FCM) lograron una precisión del 95%, destacándose como un enfoque innovador en comparación con otros algoritmos tradicionales [23].

Otro estudio relevante es el llevado a cabo por CIBERDEM, donde se aplicó una combinación de metabolómica basada en resonancia magnética nuclear y Machine Learning para encontrar biomarcadores alternativos a la glucosa en la detección temprana de la diabetes tipo 2. A través de un análisis longitudinal de ocho años, se identificaron metabólicos específicos, como las glicoproteínas y la creatina, que podrían servir como indicadores tempranos del desarrollo de la enfermedad más allá de los métodos tradicionales basados en niveles de glucosa en sangre.

Además, modelos como DeepPatient han utilizado redes neuronales profundas para analizar grandes volúmenes de datos clínicos y generar representaciones vectoriales de los pacientes, permitiendo predecir el riesgo de diabetes con alta precisión. Estos enfoques han demostrado ser superiores a los métodos tradicionales en términos de capacidad predictiva y detección temprana.

2.2.2 Comparación de técnicas utilizadas en el diagnóstico de la diabetes

En el ámbito del diagnóstico médico, y en particular en la predicción de la diabetes, el Machine Learning ha proporcionado herramientas valiosas para clasificar pacientes, predecir valores clínicos y detectar patrones en los datos de salud. Las principales técnicas aplicadas se agrupan en tres grandes categorías: clasificación, regresión y clustering, cada una con sus propios algoritmos y casos de uso [24].

- **Clasificación:** Esta técnica se utiliza para predecir categorías discretas, como determinar si un paciente es diabético o no, en función de variables clínicas.
 - Máquinas de soporte vectorial (SVM): Encuentran un hiperplano que separa las clases (diabético/no diabético) en función de sus características.
 - Árboles de decisión: Dividen los datos mediante reglas binarias basadas en las variables clínicas. Son fácilmente interpretables por profesionales de la salud.
 - Redes neuronales: Inspiradas en el cerebro humano, son capaces de realizar clasificaciones complejas y manejar relaciones no lineales en los datos clínicos.
- **Regresión:** A diferencia de clasificación, la regresión se enfoca en predecir valores continuos. En el contexto de la diabetes, puede utilizarse para estimar niveles de glucosa u otros indicadores médicos.

- Regresión lineal: Útil para relaciones simples entre variables, aunque limitada ante estructuras no lineales.
- Regresión polinómica: Captura relaciones más complejas mediante el uso de funciones no lineales.
- Redes neuronales: También se utilizan en tareas de regresión, especialmente cuando se requiere modelar patrones complejos entre múltiples variables clínicas.
- **Clustering:** Técnica no supervisada que permite agrupar pacientes según la similitud de sus características, sin necesidad de etiquetas previas. Puede emplearse para identificar subgrupos de pacientes diabéticos con perfiles de riesgo similares.
 - K-means: Asigna cada paciente a un grupo según la media de sus características más cercanas.
 - Jerárquico: Organiza los datos en niveles de similitud, creando una estructura tipo árbol que puede ser interpretada clínicamente.
 - DBSCAN: Detecta agrupaciones según la densidad de los datos, permitiendo descubrir patrones ocultos incluso en presencia de ruido.

Cada técnica tiene su lugar dependiendo de los objetivos clínicos, la disponibilidad de datos y la necesidad de interpretabilidad. En el diagnóstico de la diabetes, los algoritmos de clasificación y regresión son los más aplicados, mientras que el clustering se usa con fines exploratorios o para personalizar tratamientos. La elección adecuada del método puede marcar la diferencia en la detección temprana y el tratamiento personalizado de esta enfermedad [24].

2.3 Diagnóstico de retinopatía diabética con imágenes

2.3.1 Uso de las redes convolucionales en la detección de enfermedades oculares

La retinopatía diabética es una complicación frecuente en la diabetes que afecta a la retina, pudiendo causar ceguera si no se detecta y trata a tiempo. Según la Organización Mundial de la Salud (OMS), aproximadamente el 35% de las personas con diabetes presentan alguna forma de retinopatía diabética. Debido a la prevalencia de la enfermedad, la detección temprana es fundamental para evitar la progresión a estados más severos [25].

La retinografía, una técnica que captura imágenes del fondo de ojo ha sido tradicionalmente utilizada por oftalmólogos para diagnosticar enfermedades oculares. Sin embargo, este proceso es manual, costoso y depende de la disponibilidad de especialistas capacitados. En los últimos años, la inteligencia artificial, y en particular las redes neuronales convolucionales (CNN), han demostrado un gran potencial en la detección automática de enfermedades oculares a partir de imágenes retinianas [25].

Las redes neuronales convolucionales son modelos de aprendizaje profundo diseñados para analizar imágenes y extraer patrones relevantes de forma automática. A diferencia de los métodos tradicionales de detección, que requieren la selección manual de características, las CNN pueden aprender representaciones jerárquicas de las imágenes, identificando patrones sutiles que pueden ser indicativos de retinopatía diabética.

Varios estudios han validado la eficacia de estos modelos en la detección de la enfermedad. Por ejemplo, Google desarrolló un sistema basado en aprendizaje profundo que logró una precisión comparable a la de los especialistas humanos, utilizando un conjunto de datos con más de 120.000 imágenes de fondo de ojo (Gulshan et al., 2016). Otros estudios (Ting et al., 2017; Gargeya y Leng, 2017) han confirmado que las CNN pueden alcanzar niveles de exactitud superiores al 90% en la clasificación de retinopatía diabética [26].

Además de la detección de retinopatía, las CNN también han sido aplicadas en otras enfermedades oftalmológicas, como el glaucoma y la degeneración macular relacionada con la edad (DMAE). Para la detección de edema macular diabético, otro factor de riesgo en pacientes con diabetes, se han desarrollado modelos basados en tomografía de coherencia óptica (OCT) que permiten un diagnóstico más preciso (Roy et al., 2017) [26].

CAPÍTULO 3: OBJETIVOS

La inteligencia artificial (IA) ha demostrado ser una herramienta poderosa en la medicina moderna, permitiendo la detección temprana de enfermedades y mejorando la toma de decisiones clínicas. Este proyecto tiene como propósito el desarrollo de una aplicación basada en IA que ayude en la predicción de diabetes y en la detección de retinopatía diabética a partir de datos médicos. Para lograrlo, se definen los siguientes objetivos generales y específicos.

3.1 Objetivo General

El objetivo principal de este proyecto es el desarrollo de una aplicación basada en inteligencia artificial que permita dar soporte al médico en el diagnóstico de la diabetes a partir de datos clínicos numéricos y la detección de retinopatía diabética mediante el análisis de imágenes de fondo de ojo.

Para ello, se diseñarán e implementarán modelos de aprendizaje automático y redes neuronales que faciliten la evaluación de pacientes con posibles indicios de diabetes o complicaciones derivadas de esta enfermedad, proporcionando diagnósticos preliminares de manera eficiente y accesible. Esta solución pretende complementar el trabajo de los profesionales de la salud al ofrecer una herramienta de apoyo en la detección temprana de estas afecciones.

3.2 Objetivos Específicos

Para alcanzar el objetivo general, se han definido los siguientes objetivos específicos:

3.2.1 Construir un modelo de IA para predecir diabetes a partir de datos numéricos

La diabetes es una enfermedad crónica caracterizada por niveles elevados de glucosa en sangre, cuyos factores de riesgo incluyen antecedentes familiares, edad, obesidad y hábitos de vida. En este apartado se busca:

- Recopilar y preprocesar conjuntos de datos clínicos que contengan variables relevantes para la predicción de diabetes, como niveles de glucosa, presión arterial, índice de masa corporal (IMC) y edad.
- Aplicar técnicas de análisis exploratorio de datos (EDA) para identificar patrones en los datos y seleccionar las características más relevantes para el modelo.
- Implementar modelos de aprendizaje automático, como árboles de decisión, regresión logística, máquinas de soporte vectorial (SVM) y redes neuronales, comparando su desempeño en términos de precisión, sensibilidad y especificidad.

- Evaluar los modelos mediante métricas como matriz de confusión, precisión, recall, F1-score y área bajo la curva ROC (AUC-ROC).
- Seleccionar el modelo más adecuado y optimizar sus hiperparámetros para mejorar su capacidad predictiva.

Este modelo servirá como una herramienta de cribado preliminar, permitiendo a los usuarios obtener una estimación de su riesgo de desarrollar diabetes en función de sus datos clínicos.

3.2.2 Entrenar una red neuronal convolucional para detectar retinopatía diabética en imágenes de retina

La retinopatía diabética es una complicación grave de la diabetes que puede provocar pérdida de visión si no se detecta a tiempo. Este objetivo busca el desarrollo de un modelo basado en redes neuronales convolucionales (CNN) para la clasificación automática de imágenes de retina. Las tareas principales incluyen:

- Recopilación y preprocesamiento de imágenes médicas, asegurando un conjunto de datos balanceado con imágenes etiquetadas de pacientes con y sin retinopatía diabética.
- Aumento de datos (data augmentation) para mejorar la capacidad del modelo de generalizar y evitar el sobreajuste. Esto incluirá técnicas como rotaciones, cambios de brillo y normalización de imágenes.
- Implementación de una CNN basada en arquitecturas como VGG16, ResNet o EfficientNet, adaptada para la clasificación de imágenes médicas.
- Entrenamiento y ajuste del modelo utilizando técnicas como fine-tuning y transferencia de aprendizaje como modelos preentrenados en grandes bases de datos.
- Evaluación del rendimiento del modelo mediante métricas como precisión, recall, F1-score y AUC-ROC, asegurando que el sistema tenga un alto grado de confiabilidad en su diagnóstico.

Este modelo permitirá analizar imágenes de fondo de ojo y proporcionar una estimación sobre la presencia de signos de retinopatía diabética, facilitando la identificación temprana de la enfermedad y ayudando en la derivación oportuna de pacientes a especialistas.

3.2.3 Diseñar una interfaz que permita a los usuarios subir sus datos y obtener un diagnóstico preliminar

Para hacer accesibles los modelos desarrollados, es necesario diseñar una interfaz gráfica de usuario (GUI) o una aplicación web que permita a los usuarios interactuar con la IA de manera intuitiva. Este apartado comprende:

- Definir la arquitectura del sistema, estableciendo los flujos de información entre el usuario, la base de datos y los modelos de IA.
- Diseñar una interfaz amigable que permita a los usuarios cargar sus datos clínicos (análisis de sangre) o imágenes de retina para obtener una predicción.
- Integrar los modelos de IA en la aplicación, asegurando tiempos de respuesta adecuados y proporcionando interpretaciones comprensibles de los resultados.
- Implementar medidas de seguridad y privacidad de los datos médicos, cumpliendo con normativas de protección de datos como el Reglamento General de Protección de Datos (GDPR).
- Optimizar la experiencia del usuario, garantizando un flujo de trabajo eficiente y la correcta visualización de los resultados de predicción.

La interfaz permitirá que médicos y pacientes utilicen la herramienta de manera efectiva, facilitando la toma de decisiones informadas sobre la salud y el seguimiento de la enfermedad.

CAPÍTULO 4: HIPÓTE- SIS DEL TRABAJO

Este proyecto ha sido desarrollado mediante el uso de técnicas de aprendizaje automático, utilizando dos enfoques distintos para abordar problemas médicos concretos: una red neuronal tradicional para la predicción de diabetes a partir de datos numéricos y una red neuronal convolucional para la detección de retinopatía diabética a partir de imágenes. A continuación, se describen las herramientas, entornos y bibliotecas empleadas en cada caso.

4.1 Red neuronal para la predicción de diabetes

Para la predicción de diabetes he optado por una red neuronal artificial multicapa entrenada con datos estructurados provenientes de análisis de sangre. Las herramientas empleadas son:

4.1.1 Lenguaje

Python es un lenguaje de programación interpretado, de alto nivel, versátil y de sintaxis sencilla, lo que lo convierte en una opción muy popular para el desarrollo de software, automatización, ciencia de datos y Machine Learning. Fue creado por Guido van Rossum en 1991 y su nombre se inspira en el programa de comedia “Monty Python’s Flying Circus” [27].

Sus principales ventajas incluyen [27]:

- **Simplicidad:** su sintaxis legible y cercana al lenguaje humano permite escribir código más rápidamente.
- **Portabilidad:** puede ejecutarse en diversos sistemas operativos (Windows, macOS, Linux, Unix).
- **Gran ecosistema de bibliotecas:** permite acceder a funcionalidades avanzadas sin necesidad de programarlas desde cero.
- **Comunidad activa:** existe una gran cantidad de recursos educativos y soporte comunitario.
- **Multiparadigma:** permite programación orientada a objetos, estructurada y funcional.

Es especialmente útil en [27]:

- Desarrollo web (backend)
- Automatización de tareas mediante scripts
- Ciencia de datos y aprendizaje automático
- Prototipado de software
- Pruebas de software (testing)
- Aplicaciones de escritorio y videojuegos

4.1.2 Entorno de desarrollo

Durante las primeras fases del proyecto, la intención inicial fue utilizar Jupyter Notebook como entorno principal de trabajo debido a su naturaleza interactiva y su amplia adopción en proyectos de ciencia de datos. Sin embargo, surgieron diversos problemas de compatibilidad entre versiones de las librerías necesarias —como TensorFlow, NumPy o Scikit-learn—, lo cual afectaba a la estabilidad y reproducibilidad del proyecto. Estas incompatibilidades son relativamente comunes cuando se ejecutan modelos de aprendizaje automático en entornos que no aíslan correctamente las dependencias [28].

Para solventar estos inconvenientes, se decidió migrar el desarrollo a Anaconda, una plataforma ampliamente utilizada en ciencia de datos que permite gestionar versiones de Python y librerías mediante entornos virtuales aislados [29]. A través de Anaconda Prompt, se creó un entorno específico para este proyecto, denominado “tfg_diabetes”, en el cual se instalaron de forma controlada las versiones exactas de las dependencias requeridas. Esto permitió evitar conflictos, mejorar la estabilidad del desarrollo y garantizar la reproducibilidad del experimento, algo fundamental en proyectos de machine learning [29].

Aunque Jupyter Notebook continuó utilizándose como herramienta para ejecutar y documentar el código de manera interactiva, la gestión de paquetes, la creación del entorno y la ejecución principal del modelo se realizaron desde Anaconda. Esto permitió combinar la versatilidad del notebook con la fiabilidad que aporta la gestión de dependencias de Anaconda [28][29].



Ilustración 10 Logotipo de Anaconda.

4.1.3 NumPy

NumPy es una biblioteca esencial de Python para el cálculo numérico y científico. Permite trabajar con arrays n-dimensionales de forma eficiente, gracias a su implementación en C. Ofrece funciones avanzadas para álgebra lineal, estadísticas y manipulación de matrices, siendo mucho más rápida que las listas de Python [30].

Es muy usada en ciencia de datos y machine learning, y sirve como base para otras bibliotecas como TensorFlow o Scikit-learn. Sus operaciones vectorizadas hacen el código más legible y cercano a la notación matemática [30].



Ilustración 11 Logotipo de Numpy.

4.1.4 Pandas

Pandas es una biblioteca de Python esencial para la ciencia de datos. Permite manipular y analizar datos estructurados mediante objetos como los DataFrames, similares a tablas. Facilita tareas como carga de datos (CSV, Excel), limpieza, transformación, agrupación y análisis de series temporales. Está basada en NumPy y se integra bien con otras bibliotecas como Scikit-learn. Su facilidad de uso, flexibilidad y eficiencia la convierten en una herramienta clave para cualquier proyecto de análisis de datos en Python [31].



Ilustración 12 Logotipo de pandas.

4.1.5 Scikit-learn

Scikit-learn es una biblioteca de Python ampliamente utilizada en ciencia de datos y machine learning. Proporciona una interfaz coherente y sencilla para aplicar una gran variedad de algoritmos de aprendizaje supervisado y no supervisado, como regresión, clasificación, clustering y reducción de dimensionalidad. Su API estandarizada permite cambiar de modelo fácilmente y combinar distintos pasos de preprocesamiento mediante pipelines [32].

Ofrece herramientas para dividir datos, normalizarlos, manejar valores nulos, seleccionar variables y ajustar hiperparámetros mediante técnicas como GridSearchCV. Además, permite evaluar modelos con métricas como accuracy, r2_score o confusion_matrix. Su flexibilidad, documentación extensa y comunidad activa la convierten en una herramienta clave para proyectos de modelado predictivo y análisis estadístico [32].



Ilustración 13 Logotipo de Scikit- Learn.

4.1.6 Joblib

Joblib es una biblioteca externa de Python especializada en la ejecución paralela de tareas, la caché de resultados y la optimización del uso de memoria. Se utiliza principalmente para acelerar el procesamiento de funciones repetitivas o el trabajo con grandes volúmenes de datos. Mediante Parallel y delayed, permite distribuir tareas entre varios núcleos del procesador de forma eficiente [33].



Ilustración 14 Logotipo de JobLib.

4.1.7 Matplotlib

Matplotlib es una biblioteca de Python de código abierto para crear gráficos y visualizaciones de datos. Fue desarrollada en 2002 por John Hunter como alternativa a MATLAB y permite generar diagramas, histogramas y gráficos personalizados desde Python, especialmente útil junto con NumPy y Pandas [34].

Su módulo más utilizado es Pyplot, que ofrece una interfaz sencilla para crear gráficos. También dispone de una API orientada a objetos más flexible. A pesar de su potencia, aprender Matplotlib puede ser complicado debido a su tamaño, diversidad de interfaces y documentación a veces desactualizada [34].

Es una herramienta clave en la visualización de datos dentro del ecosistema de Data Science y Machine Learning con Python [34].

Estas herramientas me permitieron entrenar un modelo eficaz para clasificar a los pacientes entre positivos y negativos en riesgo de diabetes, basándose en variables como glucosa, presión arterial, índice de masa corporal, entre otros.




Ilustración 15 Logotipo de Matplotlib.

4.2 Red convolucional para la detección de retinopatía diabética


Para la predicción de retinopatía diabética he optado por una red neuronal convolucional, especializada en el procesamiento de imágenes médicas. Tiene herramientas comunes con la red neuronal mencionada anteriormente, como el lenguaje Python y las bibliotecas NumPy, Pandas y Matplotlib. Otras herramientas utilizadas son:

4.2.1 Entorno de desarrollo

Para el desarrollo del modelo convolucional encargado de la detección de retinopatía diabética se utilizó Visual Studio Code (VS Code) como entorno principal de programación. VS Code es un editor ligero, multiplataforma y altamente extensible que ofrece funcionalidades avanzadas como integración con Git, depuración interactiva y un sistema de extensiones que permite adaptarlo a diversos lenguajes y entornos de trabajo. Gracias a estas características, resulta especialmente adecuado para proyectos de ciencia de datos y aprendizaje profundo basados en Python [35].

Sin embargo, al igual que ocurrió con la red neuronal basada en datos numéricos, la ejecución del modelo convolucional requería un control preciso de las dependencias y versiones de librerías como TensorFlow, NumPy y Matplotlib. Por este motivo, el modelo se desarrolló dentro de un entorno virtual creado con Anaconda, lo que permitió aislar todas las bibliotecas necesarias y evitar conflictos entre versiones [29]. VS Code se configuró para utilizar el intérprete de Python correspondiente a dicho entorno (`tfg_diabetes`), garantizando así la coherencia entre el código ejecutado en este editor y el entorno configurado previamente en Anaconda Prompt.

Esta combinación (VS Code como entorno de edición y un entorno virtual de Anaconda como base de ejecución) permitió desarrollar el modelo convolucional de forma estable, reproducible y con una gestión eficiente de dependencias, asegurando que el comportamiento observado durante el entrenamiento y la inferencia fuera consistente a lo largo de todo el proyecto [35][29].



CAPÍTULO 5: METODOLOGÍA Y RESULTADOS

En este capítulo se detalla la metodología utilizada y los resultados obtenidos en la implementación de la red neuronal y convolucional, así como de la interfaz desarrollada para su utilización.

5.1 Planificación del proyecto

La planificación de un proyecto es una fase esencial que permite definir de forma estructurada las tareas a realizar, los recursos necesarios y los plazos estimados para cumplir los objetivos marcados. En el contexto de este Trabajo de Fin de Grado, la planificación ha sido una herramienta clave para organizar de manera efectiva todas las fases del proyecto: desde el estudio preliminar hasta el desarrollo del modelo de inteligencia artificial y la implementación de la interfaz web [36].

Antes de comenzar el desarrollo práctico, se realizó una división detallada de las tareas en bloques de trabajo, lo cual ha permitido controlar el progreso, detectar posibles desviaciones temporales y distribuir el esfuerzo de forma equilibrada. Para ello, se utilizaron herramientas de gestión de proyectos que han facilitado tanto el desglose de tareas como la visualización del cronograma en forma de diagrama de Gantt [36].

5.1.1 Desglose de tareas (WBS)

El desglose de tareas, conocido como Work Breakdown Structure (WBS), consiste en fragmentar el proyecto en tareas más pequeñas y manejables, agrupadas por fases lógicas como investigación, diseño, desarrollo y documentación. Esta estructura permite visualizar con claridad las actividades necesarias, su secuencia y el esfuerzo estimado de cada una [37].

En la figura siguiente se presenta el desglose de tareas utilizado en este trabajo. Para su elaboración se ha empleado la herramienta Excel que ha permitido organizar de forma jerárquica todas las tareas junto con su duración estimada y dependencias [37].

INVESTIGACIÓN			
Nº	Tarea	Esfuerzo estimado (h)	Dependencias
1	Investigación sobre redes neuronales	6	-
2	Investigación sobre redes convolucionales	6	Investigación sobre redes neuronales
3	Estudio del lenguaje Python	10	-
4	Estudio sobre librerías de python	12	Estudio del lenguaje Python
5	Investigación sobre diabetes	4	-
6	Investigación sobre retinopatía diabética	6	5Investigación sobre diabetes
7	Búsqueda de dataset	3	Investigación sobre retinopatía diabética
8	Estudio de la plataforma Jupyter Notebook	3	Estudio del lenguaje Python
9	Estudio sobre cómo entrenar una ia	5	Investigación sobre redes neuronales, Estudio del lenguaje Python
10	Investigación sobre técnicas de clasificación binaria	5	Investigación sobre redes neuronales, Estudio sobre librerías de python
11	Estudio sobre Streamlit	4	Estudio del lenguaje Python, Estudio de la plataforma Jupyter Notebook
12	Investigación sobre métricas de evaluación de modelos	5	Estudio sobre cómo entrenar una ia, Investigación sobre técnicas de clasificación binaria
13	Investigación sobre técnicas de data augmentation	4	Investigación sobre redes convolucionales, Búsqueda de dataset
14	Estudio sobre gestión de datasets desequilibrados	4	Búsqueda de dataset, Investigación sobre técnicas de clasificación binaria
	TOTAL ESFUERZO ESTIMADO (h)	77	

Ilustración 16 Desglose de tareas correspondientes a la fase de investigación del proyecto, con su esfuerzo estimado y dependencias.

DISEÑO			
Nº	Tarea	Esfuerzo estimado (h)	Dependencias
1	Definición de la arquitectura de la red neuronal	8	Investigación sobre técnicas de clasificación binaria
2	Definición de la arquitectura de la red convolucional	8	Investigación sobre CNN y retinopatía diabética
3	Diseño de la interfaz de usuario	6	Estudio sobre Streamlit
4	Definición del flujo de la aplicación web	6	Definición de arquitectura y diseño de IU
TOTAL ESFUERZO ESTIMADO (h)		28	

Ilustración 18 Desglose de tareas de la fase de diseño del proyecto, incluyendo la definición de arquitecturas y del flujo de la aplicación, con su esfuerzo estimado.

DESARROLLO			
Nº	Tarea	Esfuerzo estimado (h)	Dependencias
1	Limpieza y preparación del dataset	2	Búsqueda de dataset
2	Creación de la arquitectura de la red neuronal (RRNN)	4	Definición de la arquitectura de la red neuronal
3	Entrenamiento y optimización de la RRNN	8	Definición de la arquitectura de la red neuronal, Limpieza y preparación del dataset
4	Creación de la arquitectura de la red convolucional (CNN)	5	Definición de la arquitectura de la red convolucional
5	Entrenamiento y optimización de la CNN	10	Creación de la arquitectura de la red convolucional (CNN), Limpieza y preparación del dataset
6	Evaluación del rendimiento de modelos	4	Entrenamiento y optimización de la RRNN, Entrenamiento y optimización de la CNN
7	Hacer predicciones con el modelo	3	Evaluación del rendimiento de modelos
8	Guardado del modelo implementado	2	Entrenamiento y optimización de la RRNN, Entrenamiento y optimización de la CNN
9	Desarrollo de la interfaz web	6	Diseño de la interfaz de usuario, Definición del flujo de la aplicación web
10	Integración del modelo con la interfaz web (implementación)	6	Guardado del modelo implementado, Desarrollo de la interfaz web
TOTAL ESFUERZO ESTIMADO (h)		50	

Ilustración 17 Desglose de tareas de la fase de desarrollo del proyecto, detallando las actividades de implementación, entrenamiento de modelos e integración, junto con el esfuerzo estimado.

DOCUMENTACIÓN			
Nº	Tarea	Esfuerzo estimado (h)	Dependencias
1	Redacción de la memoria final	90	-
TOTAL ESFUERZO ESTIMADO (h)		90	

Ilustración 19 Desglose de tareas de la fase de documentación del proyecto, indicando el esfuerzo total dedicado a la redacción de la memoria final.

5.1.2 Diagrama de Gantt

El diagrama de Gantt es una herramienta gráfica utilizada para representar visualmente el cronograma de un proyecto. Cada tarea se representa como una barra horizontal, cuya longitud indica su duración estimada. Además, se puede visualizar la dependencia entre tareas y el solapamiento temporal de las mismas [38].

En este proyecto, el diagrama de Gantt ha permitido tener una visión global del calendario, facilitando la distribución de tiempos entre las diferentes fases: investigación, desarrollo de la red neuronal convolucional, entrenamiento, pruebas, implementación de la interfaz web y documentación final. Esta representación ha sido útil para gestionar de forma eficiente los plazos y garantizar la entrega en los tiempos establecidos [38].

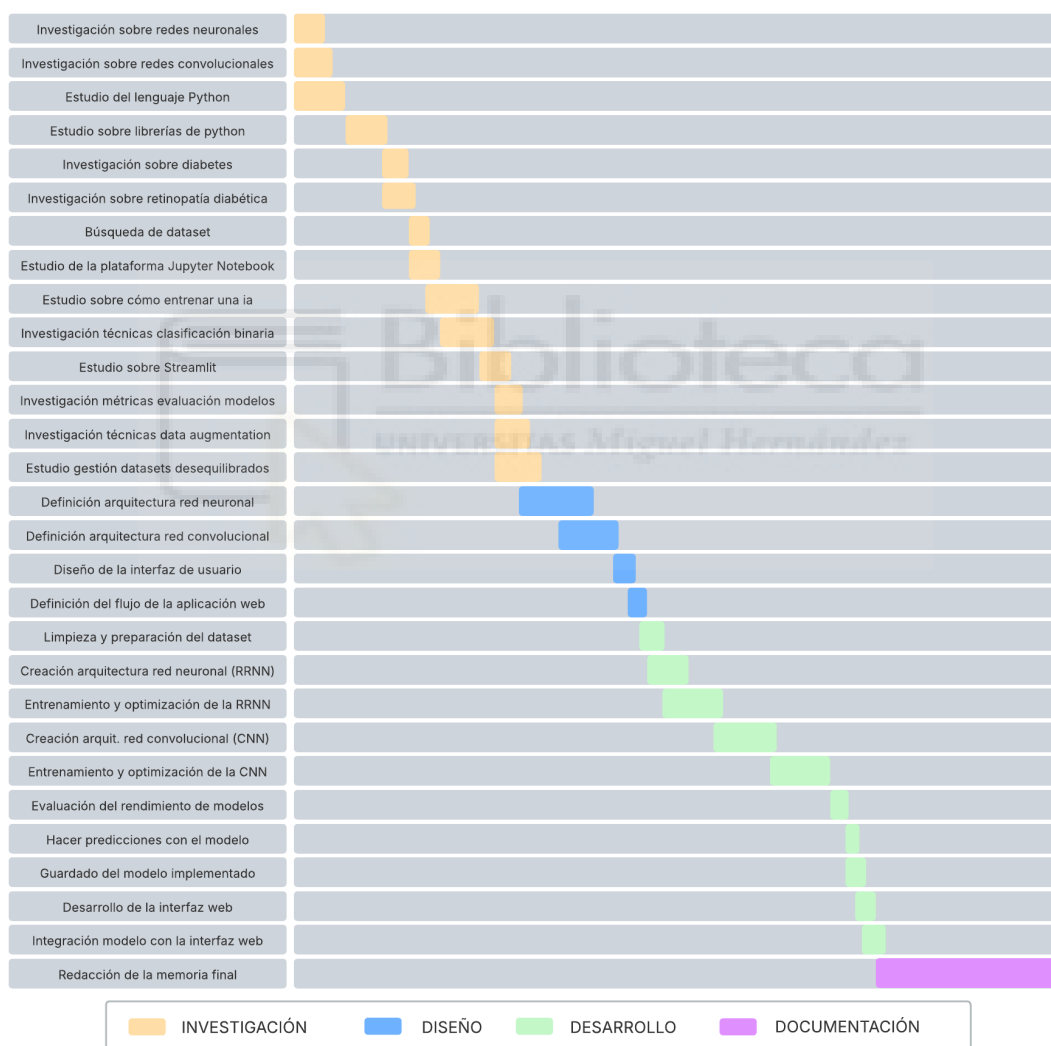


Ilustración 20 Diagrama de Gantt del proyecto, donde se representa la planificación temporal de las distintas fases y tareas a lo largo del desarrollo del trabajo.

5.2 Desarrollo red neuronal

5.2.1 Dataset para la predicción de diabetes

Para entrenar la red neuronal encargada de la predicción de diabetes, se ha utilizado el conjunto de datos Pima Indians Diabetes Database, disponible públicamente en la plataforma Kaggle (UCI Machine Learning). Este dataset contiene información médica recopilada de mujeres de origen Pima, con variables numéricas que describen características fisiológicas y de salud, con el objetivo de predecir si una persona padece diabetes o no [39].

El dataset consta de 768 registros y 9 columnas: 8 características de entrada y 1 columna de salida binaria (outcome), donde 1 indica presencia de diabetes y 0 ausencia [39].

Las variables incluidas son:

- Pregnancies: Número de embarazos.
- Glucose: Concentración de glucosa en sangre.
- BloodPressure: Presión arterial diastólica (mm Hg).
- SkinThickness: Espesor del pliegue cutáneo del tríceps (mm).
- Insulin: Niveles de insulina en sangre (mu U/ml).
- BMI: Índice de masa corporal (peso en kg/ altura en m²).
- DiabetesPedigreeFunction: Función de pedigree de diabetes (historial familiar).
- Age: Edad (en años).
- Outcome: Diagnóstico de diabetes (0 o 1).

Análisis estadístico básico

A continuación, se muestran algunas estadísticas generales del conjunto de datos:

Variable	Media	Mínimo	Máximo
Glucose	120.9	0	199
BloodPressure	69.1	9	122
SkinThickness	20.5	0	99
Insulin	79.8	0	846
BMI	31.9	0	67.1
DiabetesPedigreeFunction	0.47	0.08	2.42
Age	33.2	21	81

Se observa que algunas variables presentan valores 0 que no son fisiológicamente posibles (como Glucose, BloodPressure o BMI), lo que sugiere la necesidad de una limpieza o imputación previa antes del entrenamiento del modelo.

Visualización de la distribución del target

La variable Outcome presenta un desequilibrio:

- 268 casos positivos (34.9%)
- 500 casos negativos (65.1%)

Este desbalance fue tenido en cuenta en el diseño y entrenamiento del modelo, aplicando técnicas como el oversampling o `class_weight`.

5.2.2 Métricas de evaluación del modelo

En problemas de clasificación binaria como el diagnóstico de diabetes, es fundamental contar con métricas que permitan evaluar el rendimiento del modelo de forma adecuada. La simple proporción de aciertos (exactitud) no siempre es suficiente, especialmente cuando el conjunto de datos está desequilibrado, como ocurre en este caso, donde las clases positiva (diabetes) y negativa (sin diabetes) no están igualmente representadas.

Matriz de confusión

Una herramienta esencial para entender el comportamiento del clasificador es la matriz de confusión, que resume los aciertos y errores del modelo. Se estructura de la siguiente forma [40]:

	Predicho: 0	Predicho: 1
Real: 0 (negativo)	TN	FP
Real: 1 (positivo)	FN	TP

- TP (True Positive): Casos correctamente clasificados como positivos (diabetes).
- TN (True Negative): Casos correctamente clasificados como negativos (no diabetes).
- FP (False Positive): Casos incorrectamente clasificados como positivos.
- FN (False Negative): Casos incorrectamente clasificados como negativos.

Métricas derivadas

A partir de la matriz de confusión, se pueden obtener varias métricas relevantes [40]:

- Exactitud (Accuracy):

Proporción total de predicciones correctas.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- Precisión (Precision):

Proporción de verdaderos positivos sobre el total de predicciones positivas. Indica la fiabilidad de las predicciones positivas.

$$Precision = \frac{TP}{TP + FP}$$

- Exhaustividad o Sensibilidad (Recall):

Proporción de verdaderos positivos sobre el total de casos positivos reales. Mide la capacidad del modelo para detectar correctamente los positivos.

$$Recall = \frac{TP}{TP + FN}$$

- Valor-F (F1 Score):

Media armónica entre precisión y exhaustividad. Es especialmente útil cuando hay desequilibrio de clases.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Interpretación de resultados

La matriz de confusión obtenida se muestra en la siguiente figura:




Ilustración 21 Matriz de confusión del modelo mejorado

Esta matriz representa el desempeño del modelo sobre el conjunto de pruebas. En ella se observa que:

- Verdaderos negativos (TN): 70 → Personas sanas correctamente clasificadas.
- Falsos positivos (FP): 29 → Personas sanas clasificadas erróneamente como diabéticas.
- Falsos negativos (FN): 13 → Personas con diabetes clasificadas como sanas.
- Verdaderos positivos (TP): 42 → Personas con diabetes correctamente identificadas.

Métricas de clasificación

Métrica	Clase Negativa	Clase Positiva
Precisión	0.84	0.59
Recall (Exhaustividad)	0.71	0.76
F1-Score	0.77	0.67

- Exactitud general (Accuracy): 72.73%
- Promedio macro (media aritmética entre clases): 72% aproximadamente.

La métrica más relevante en este tipo de problemas médicos es el recall de la clase positiva, ya que representa la proporción de personas con diabetes correctamente detectadas. Este valor ha aumentado de forma significativa respecto a versiones anteriores del modelo, alcanzando un 76%, lo que indica una capacidad sólida del sistema para identificar correctamente pacientes con la enfermedad.

Aunque la precisión (proporción de positivos predichos que realmente son positivos) ha descendido ligeramente, este comportamiento es esperado en contextos donde se prioriza la minimización de falsos negativos. En el ámbito sanitario, es preferible alertar falsamente a una persona sana (falso positivo) que no detectar a una persona enferma (falso negativo).

En conjunto, el modelo presenta un rendimiento equilibrado y ajustado al objetivo clínico del proyecto, permitiendo un diagnóstico temprano potencialmente útil como herramienta de apoyo a profesionales médicos.

5.2.3 Preprocesamiento de los datos

Antes de proceder con el entrenamiento del modelo de red neuronal, fue necesario realizar un preprocesamiento exhaustivo del conjunto de datos para garantizar su calidad y adecuación al problema de clasificación.

En primer lugar, se cargó el conjunto de datos Pima Indians Diabetes Database desde Kaggle, compuesto por 768 registros y 9 columnas: ocho variables independientes y una variable objetivo-binaria (outcome). Se llevó a cabo una exploración inicial para identificar posibles inconsistencias. Aunque el dataset no contenía valores nulos explícitos, sí presentaba valores igual a cero en atributos donde no son clínicamente viables, como la glucosa, la insulina, etc.

Estos valores fueron considerados como ausencias encubiertas, por lo que se procedió a sustituirlos por la mediana de cada columna correspondiente. Esta técnica de imputación permite mantener la distribución de los datos sin introducir valores extremos que podrían sesgar el entrenamiento del modelo.

Una vez limpio, el conjunto de datos fue dividido en subconjuntos de entrenamiento (80%) y prueba (20%) mediante la función `train_test_split()` de Scikit-learn, con una semilla fija (`random_state=42`) para garantizar la reproducibilidad.

Este preprocesamiento fue clave para preparar adecuadamente los datos de entrada y minimizar errores derivados de información inválida o mal estructurada, sentando las bases para un entrenamiento efectivo del modelo de red neuronal.

5.2.4 Arquitectura de la red neuronal

La red neuronal desarrollada para la predicción de diabetes se ha implementado utilizando el clasificador `MLPClassifier` de la librería `scikit-learn`, el cual permite construir redes neuronales multicapa (MLP, Multilayer Perceptron). Este tipo de red es especialmente útil para tareas de clasificación binaria como la que se aborda en este trabajo [41].

La arquitectura definida consta de las siguientes capas [42]:

- **Capa de entrada:** compuesta por 8 neuronas, una por cada característica del dataset (Pregnancies, Glucose, BloodPressure, SkinThickness, Insulin, BMI, DiabetesPedigreeFunction y Age).
- **Primera capa oculta:** 10 neuronas con función de activación ReLU (Rectified Linear Unit), que introduce no linealidad al modelo y mejora el aprendizaje de relaciones complejas.
- **Segunda capa oculta:** 10 neuronas también con activación ReLU.
- **Capa de salida:** una sola neurona con función de activación sigmoide, que devuelve una probabilidad entre 0 y 1 para determinar si el resultado predice diabetes (1) o no (0).

5.2.5 Entrenamiento del modelo

El proceso de entrenamiento del modelo constituye una fase clave en el desarrollo del sistema de predicción de diabetes. En este apartado se documentan los distintos intentos realizados para entrenar la red neuronal, detallando para cada uno de ellos la arquitectura utilizada, los parámetros configurados, los resultados obtenidos y las conclusiones extraídas.

Cada entrenamiento incluirá una descripción detallada de la estructura de la red neuronal empleada, así como los criterios de evaluación y los cambios implementados respecto a entrenamientos anteriores. Esta información permite ofrecer una visión completa y transparente del proceso de mejora progresiva del modelo hasta alcanzar un rendimiento aceptable.

5.2.5.1 Primer entrenamiento

En un primer intento se entrenó una red neuronal multicapa (MLPClassifier) con dos capas ocultas de 10 neuronas cada una, utilizando el solver 'adam' y un máximo de 1000 iteraciones. No se aplicó ningún tipo de balanceo en las clases, lo que generó un modelo sesgado hacia la clase negativa (no diabéticos), debido al desequilibrio en el conjunto de entrenamiento.

Parámetros principales del modelo:

- Arquitectura: 2 capas ocultas de 10 neuronas cada una
- Solver: 'adam'
- max_iter: 1000
- Sin técnicas de balanceo de clases
- Dataset original con clases desbalanceadas

Resultados obtenidos:

- Precisión global: 74%
- Matriz de confusión:




Ilustración 22 Matriz de confusión primer entrenamiento

El modelo presenta un mejor rendimiento identificando pacientes sin diabetes (clase 0), con una precisión del 74% y un recall del 82. Sin embargo, su rendimiento para detectar

casos positivos (diabetes) es más bajo, con una precisión del 60% y un recall del 49%, lo cual indica que el modelo tiende a pasar por alto algunos casos reales de diabetes. Esto puede deberse al desbalance de clases (99 casos negativos vs 55 positivos) o a la simplicidad del modelo.

5.2.5.2 Segundo entrenamiento

Tras aplicar técnicas de mejora sobre el modelo inicial, se entrenó una red neuronal más profunda compuesta por tres capas ocultas con 32, 16 y 8 neuronas respectivamente. Además, he utilizado sobremuestreo mediante RandomOverSampler para equilibrar las clases del conjunto de entrenamiento y StandardScaler para normalizar los datos. El entrenamiento se controló con early_stopping para evitar sobreajuste.

Este modelo obtuvo los siguientes resultados:

- Precisión global: 73,38%
- Clase 0 – No diabético:
 - Precisión: 86%
 - Recall: 70%
 - F1-score: 77%
- Clase 1: Diabético:
 - Precisión: 59%
 - Recall: 80%
 - F1-score: 68%
- La matriz de confusión resultando es:




Ilustración 23 Matriz confusión segundo entrenamiento

Se observa una mejora notable en el recall de la clase positiva (diabéticos), que pasó del 49% en el primer modelo al 80%, indicando que el modelo ahora es mucho más efectivo detectando casos reales de diabetes, aunque a costa de un ligero aumento en los falsos positivos.

Este compromiso es aceptable y deseable en un contexto médico, donde es preferible detectar más casos sospechosos para su posterior evaluación, aunque aumente el número de personas sanas clasificadas erróneamente como positivas.

5.2.5.3 Tercer entrenamiento

Con el objetivo de encontrar una arquitectura óptima para la red neuronal, se implementó una búsqueda automatizada de hiperparámetros mediante GridSearchCV, herramienta de scikit-learn que permite evaluar múltiples combinaciones de configuraciones a través de validación cruzada.

En esta fase se exploraron diferentes estructuras de red (variando el número de capas y neuronas), funciones de activación (relu y tanh), niveles de regularización (alpha) y número de iteraciones máximas (max_iter). Los datos se mantuvieron balanceados mediante sobremuestreo y normalizados previamente.

El mejor modelo obtenido mediante GridSearch presentó la siguiente matriz de confusión:

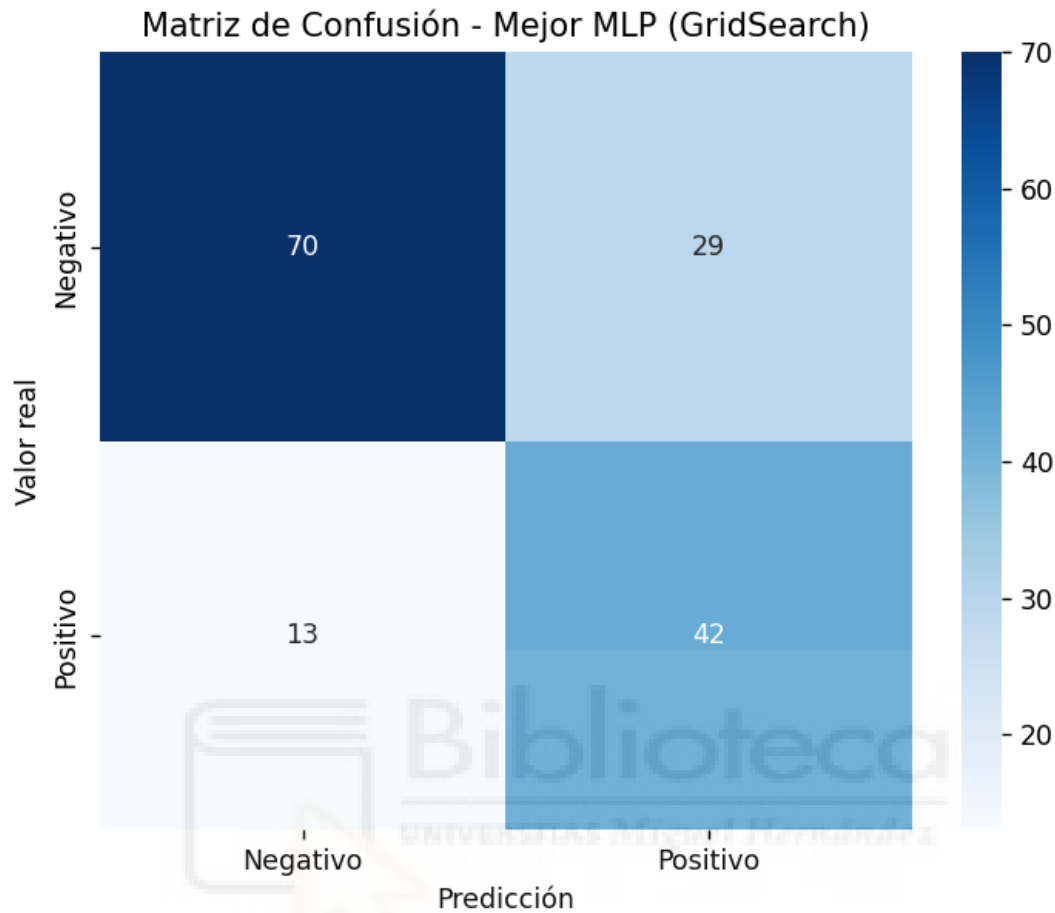


Ilustración 24 Matriz de confusión tercer entrenamiento

Y las métricas correspondientes:

- Precisión global: 72,73%
- F1-score clase 1 (diabetes): 0,67
- Recall clase 1: 76%
- Recall clase 0: 71%

Si bien los resultados fueron satisfactorios en términos generales, no representaron una mejora significativa con respecto al modelo del segundo entrenamiento, que había logrado un recall del 80% y un F1-score de 0,68 en la clase positiva, manteniendo además una precisión global ligeramente superior (73,38%).

Por ello, se concluyó que el modelo obtenido en el segundo entrenamiento era más adecuado que este tercer modelo así que no se siguió investigando por esta rama.

5.2.5.4 Resultados entrenamiento con Dataset Extendido

Tras una primera fase experimental con el dataset Pima Indians (768 registros), se detectó que el volumen de datos era insuficiente para garantizar la generalización de la Red Neuronal Profunda (MLP). Siguiendo las recomendaciones de la literatura científica para modelos de Deep Learning, se procedió a reentrenar el sistema utilizando el Diabetes Prediction Dataset, aumentando el volumen de entrenamiento a 100.000 registros clínicos.

Los resultados obtenidos tras el reentrenamiento muestran una mejora significativa en la robustez del modelo:

- Exactitud Global (Accuracy): 90.95%
- Sensibilidad (Recall) para Diabetes: 88%

A continuación, se presenta la matriz de confusión resultante sobre el conjunto de test:

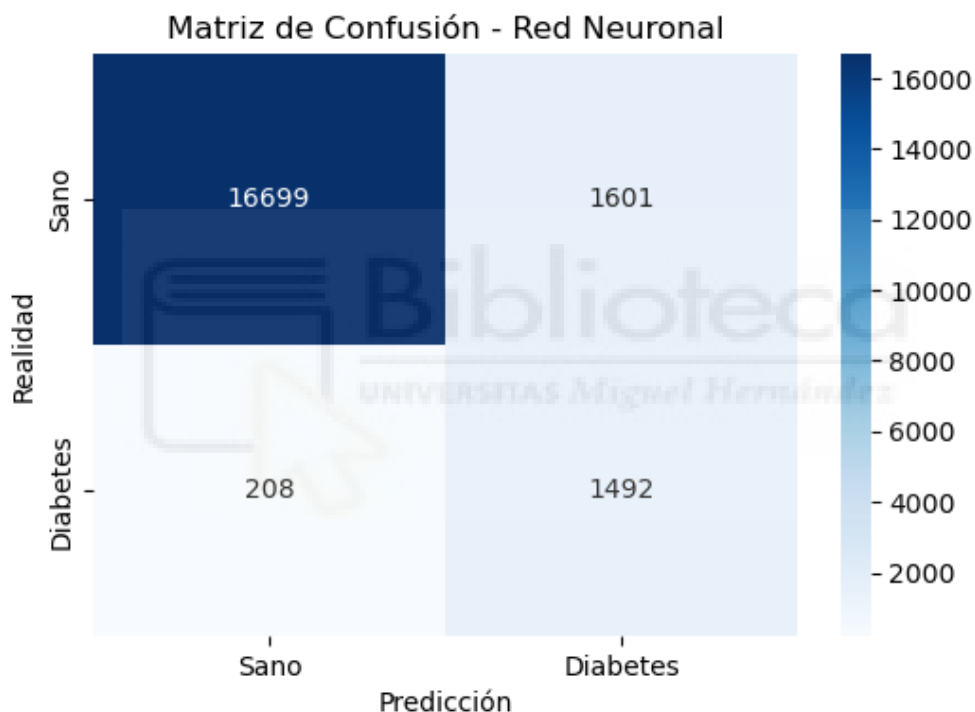


Ilustración 25 Matriz de confusión dataset extendido

Se observa que el modelo ha identificado correctamente a 1.492 pacientes diabéticos (Verdaderos Positivos), fallando únicamente en 208 casos (Falsos Negativos). Esto demuestra una alta capacidad de detección.

Por otro lado, la precisión de la clase positiva es del 48%, lo que indica un número moderado de Falsos Positivos (1.601). Este comportamiento es intencionado y deseable en sistemas de apoyo al diagnóstico médico: se ha priorizado maximizar la sensibilidad (Recall) para minimizar el riesgo de no detectar la patología existente. En un entorno real, los casos positivos detectados por la IA pasarían a una segunda revisión médica confirmatoria, por lo que el “coste” de un falso positivo es bajo comparado con el riesgo de un falso negativo.

5.3 Desarrollo de la red convolucional

El objetivo de esta parte del trabajo es diseñar y entrenar una red neuronal convolucional (CNN) capaz de predecir, a partir de una imagen de fondo de ojo, si el paciente presenta signos de retinopatía diabética o no. A diferencia de otros enfoques que clasifican la enfermedad en varios grados, en este proyecto se optó finalmente por un esquema binario, más alineado con el uso de la aplicación: ofrecer un prediagnóstico rápido (retinopatía | sin retinopatía).

5.3.1 Preparación del conjunto de datos para la CNN

Antes de definir la arquitectura se llevaron a cabo diversos ajustes en el dataset de imágenes, ya que el conjunto original presentaba varios problemas que afectaban directamente al entrenamiento:

- En primer lugar, se reorganizaron todas las imágenes en una estructura de carpetas por clase. Inicialmente se disponía de las cinco categorías habituales (0, 1, 2, 3 y 4 según el nivel de gravedad de la enfermedad), pero para este trabajo se agruparon en dos clases:
 - Clase 0: imágenes sin retinopatía diabética
 - Clase 1: imágenes con algún grado con retinopatía diabética (clases 1-4 del dataset original).
- Durante este proceso se detectaron inconsistencias (imágenes en carpetas incorrectas, ficheros duplicados o dañados) que se corrigieron manualmente o se eliminaron para evitar que el modelo aprendiera a partir de datos erróneos.
- Asimismo, se revisó el desequilibrio de clases. Dado que el número de imágenes sin retinopatía era superior al de imágenes con retinopatía, se aplicaron estrategias de equilibrado parcial, combinando una ligera reducción de la clase mayoritaria y el uso intensivo de aumento de datos (data augmentation) sobre la clase minoritaria durante el entrenamiento.

Las imágenes se redimensionaron a un tamaño fijo y se normalizaron dividiendo los valores de los píxeles entre 255, de modo que todos los valores quedasen en el rango 0, 1. Para alimentar la red se utilizó un generador de imágenes de Keras (ImageDataGenerator), configurado con las mismas transformaciones tanto en el entrenamiento como en la validación:

- Conjunto de entrenamiento: rotaciones, pequeños desplazamientos, zoom y ligeros cambios de brillo, con el fin de aumentar la variabilidad y reducir el sobreajuste.
- Conjunto de validación y prueba: únicamente reescalado y redimensionado, sin transformaciones geométricas ni de color, para medir el rendimiento de manera realista.

5.3.2 Arquitectura de la red convolucional

Dado que el objetivo de este trabajo es implementar y comprender el funcionamiento de una CNN propia, se optó por una arquitectura desde cero, sin utilizar modelos preentrenados. La estructura seguida fue al de una CNN clásica, sencilla pero suficiente para este problema:

- Un bloque inicial de capas convolucionales con filtros pequeños (por ejemplo, 3x3), cada una seguida de una función de activación ReLU y una capa de max-pooling para reducir la dimensión espacial y extraer las características más relevantes.
- A medida que avanza la red se incrementa el número de filtros, de forma que las primeras capas capturan patrones básicos (bordes contrastes) y las últimas capas aprenden características más complejas asociadas a las lesiones típicas de la retinopatía (microaneurismas, exudados, hemorragias, etc.).
- Tras las capas convolucionales, se incluyen una operación de aplanado (Flatten) y una o dos capas densas. Para mejorar la capacidad de generalización se incorporan capas de Dropout, que desactivan aleatoriamente un porcentaje de neuronas durante el entrenamiento y ayudan a reducir el sobreajuste.
- La capa de salida está formada por una única neurona con activación sigmoide, que devuelve un valor entre 0 y 1 interpretable como probabilidad de que la imagen corresponda a un paciente con retinopatía diabética.

El modelo se compiló utilizando la función de pérdida binary cross-entropy, el optimizador Adam y la métrica principal de evaluación accuracy, complementada en el análisis posterior con precisión, exhaustividad y matriz de confusión.

5.3.3 Proceso de entrenamiento y ajustes

El entrenamiento de la CNN se realizó en varias fases, ajustando progresivamente los hiperparámetros en función de los resultados obtenidos:

1. Número de épocas y tamaño de lote

Se comenzaron con un número moderado de épocas y un tamaño de lote adaptado a la memoria disponible. Tras las primeras pruebas se observó que el modelo tendía a sobreajustar si se entrenaba demasiadas épocas sin control, por lo que se añadió una estrategia de early stopping, deteniendo el entrenamiento cuando la pérdida de validación dejaba de mejorar.

2. Verificación de la coherencia datos-modelo

Durante las primeras pruebas se detectaron resultados poco realistas (por ejemplo, precisiones extremadamente altas que no se correspondían con el comportamiento real al probar la red en imágenes nuevas). Esto puso de manifiesto la necesidad de revisar de nuevo el pipeline de datos, comprobando que:

- El reescalado y el tamaño de las imágenes en la fase de inferencia coincidían exactamente con los utilizados en el entrenamiento.

- La interpretación de la salida de la capa sigmoide era correcta, es decir, que los umbrales y el mapeo 0/1 se correspondían con la definición de las clases en los generadores de datos.
- No existía fuga de información entre entrenamientos y validación (por ejemplo, imágenes repetidas en ambos conjuntos).

Una vez corregidos estos aspectos y depurado el código, las métricas obtenidas resultaron más coherentes con el nivel de complejidad del problema y con el tamaño del conjunto de datos disponible.

3. Evaluación final

El modelo definitivo se entrenó utilizando el conjunto de entrenamiento ajustado y se evaluó sobre un conjunto de prueba independiente. Además del accuracy global, se analizaron la matriz de confusión y las métricas por clase, con especial atención a la tasa de falsos negativos, dado que en el contexto médico es especialmente crítico no pasar por alto casos de pacientes con retinopatía diabética.

5.3.4 Integración del modelo en la aplicación

Una vez entrenada y validada, la red convolucional se exportó a un fichero de modelo y se integró en la interfaz desarrollada para este trabajo. La aplicación permite al usuario cargar una imagen de fondo de ojo, que se preprocesa aplicando las mismas operaciones descritas anteriormente (redimensionado y normalización), y se pasa a la CNN para obtener una predicción binaria. El resultado se muestra junto con la probabilidad estimada por el modelo, acompañada de un aviso explícito de que se trata de una herramienta de apoyo al diagnóstico que no sustituye en ningún caso la valoración de un profesional sanitario.

5.4 Resultados de la red convolucional

Una vez entrenada la red convolucional binaria para la detección de retinopatía diabética, se evaluó su rendimiento utilizando el conjunto de imágenes organizado en dos clases: clase 0 (sin retinopatía) y clase 1 (con retinopatía, agrupando cualquier grado de la enfermedad). En total se evaluaron 3662 imágenes, de las cuales 1805 pertenecían a la clase 0 y 1857 a la clase 1.

5.4.1 Comportamiento durante el entrenamiento

Durante el entrenamiento se monitorizaron las curvas de accuracy y los valores de pérdida tanto en el conjunto de entrenamiento como en el de validación. En general, se observó una mejora progresiva del rendimiento en las primeras épocas, seguida de una estabilización, lo que indica que el modelo fue capaz de aprender patrones relevantes en las imágenes.

El uso de regularización L2 y capas de dropout ayudó a reducir el sobreajuste, de manera que las curvas de entrenamiento y validación se mantuvieron relativamente próximas, sin divergencias acusadas. Además, se empleó parada temprana (early stopping), deteniendo el entrenamiento cuando la pérdida de validación dejaba de

mejorar durante varias épocas consecutivas y conservando los mejores pesos del modelo.

5.4.2 Métricas globales de rendimiento

La evaluación cuantitativa se realizó haciendo predicciones sobre las 3662 imágenes del conjunto binario y comparándolas con sus etiquetas reales. El resumen de métricas obtenido mediante el classification report de scikit-learn fue el siguiente:

- Accuracy global: 0,95
- Clase 0 (sin retinopatía)
 - Precisión: 0,95
 - Recall: 0,95
 - F1-score: 0,95
 - Soporte: 1805 imágenes
- Clase 1 (con retinopatía)
 - Precisión: 0,95
 - Recall: 0,95
 - F1-score: 0,95
 - Soporte: 1857 imágenes

Estos resultados indican que el modelo no solo alcanza una precisión global elevada (95%) sino que además mantiene un comportamiento equilibrado entre ambas clases, algo especialmente relevante en el contexto médico, donde suele ser habitual que el rendimiento sea muy distinto en la clase “sana” y en la clase “enferma”.

5.4.3 Matriz de confusión e interpretación

La matriz de confusión obtenida muestra que la mayoría de las imágenes se clasifican correctamente en su clase correspondiente, con un porcentaje de aciertos cercano al 95% tanto para la clase 0 como para la clase 1. Existen todavía algunos falsos negativos (casos de retinopatía clasificados como “sin retinopatía”) y falsos positivos (imágenes sin retinopatía clasificadas como “con retinopatía”), aunque su número es relativamente reducido respecto al total de muestras.




Ilustración 26 Matriz de confusión CNN binaria

Desde el punto de vista clínico, los falsos negativos son los más críticos, ya que implican no detectar a un paciente que sí presenta signos de retinopatía diabética. Aunque el modelo consigue una sensibilidad (recall) del 95% para la clase positiva, estos casos siguen representando un límite importante de la herramienta y refuerzan la idea de que debe utilizarse como apoyo al diagnóstico y no como sustituto de la valoración profesional.

5.4.4 Validación cualitativa mediante probabilidades

Además de las métricas agregadas, se analizaron ejemplos individuales de predicción, observando las probabilidades devueltas por la capa sigmoide. Por ejemplo, en algunas imágenes sin retinopatía el modelo asigna probabilidades bajas de enfermedad (por debajo de 0,1), mientras que en imágenes con signos claros de retinopatía la probabilidad de la clase positiva se sitúa próxima a 1. Este comportamiento cualitativo es coherente con las métricas globales y sugiere que la red ha aprendido a distinguir patrones visuales característicos de la patología.

5.4.5 Limitaciones de la evaluación

Es importante señalar que esta evaluación se ha realizado sobre el conjunto completo de imágenes reorganizadas en formato binario, sin separar explícitamente un subconjunto de prueba totalmente independiente del proceso de entrenamiento inicial. Por tanto,

aunque las métricas obtenidas son muy buenas y coherentes con el comportamiento observado en la práctica, es posible que estén ligeramente sobreestimadas respecto a un escenario de validación externa estricta.

Aun así, los resultados permiten concluir que la red convolucional desarrollada constituye una base sólida para la detección automática de retinopatía diabética en imágenes de fondo de ojo, y que, con un mayor control sobre los conjuntos de entrenamiento y prueba y con la incorporación de más datos, podría servir como herramienta fiable de apoyo al diagnóstico en entornos reales.

5.5 Conclusiones parciales sobre el modelo de detección de retinopatía diabética

El desarrollo y evaluación del modelo convolucional permitieron comprobar que una red neuronal relativamente sencilla, entrenada desde cero y utilizando imágenes reorganizadas en formato binario, es capaz de detectar retinopatía diabética con un nivel de precisión muy elevado. A diferencia de arquitecturas preentrenadas complejas, el enfoque empleado en este trabajo se centra en comprender el proceso completo (desde la construcción del dataset hasta la interpretación de las predicciones) y en demostrar la viabilidad de integrar un modelo funcional dentro de una aplicación real.

Los resultados obtenidos muestran que la red alcanza un 95% de accuracy, con valores de precisión, recall y F1-score también del 95% en ambas clases. Este equilibrio entre clases es especialmente relevante, ya que evita el sesgo habitual hacia la clase mayoritaria, muy frecuente en problemas médicos. La matriz de confusión indica que la mayoría de las imágenes se clasifican correctamente y que el número de falsos positivos y falsos negativos es bajo. No obstante, aunque el modelo demuestra una capacidad clara para identificar características visuales típicas de la retinopatía diabética, los falsos negativos siguen representando un aspecto crítico, ya que podrían retrasar la derivación de un paciente a una revisión especializada.

Asimismo, las pruebas realizadas mediante la aplicación permiten validar que la red generaliza adecuadamente cuando analiza imágenes externas al conjunto utilizado en entrenamiento, siempre que se respeten las mismas condiciones de preprocesamiento. No obstante, la evaluación también pone de manifiesto que el rendimiento podría verse influido por factores como la calidad de la imagen, la iluminación o el contraste, aspectos especialmente relevantes en contextos clínicos reales.

En conjunto, este modelo demuestra que incluso con una arquitectura moderada y un dataset reorganizado de forma manual es posible alcanzar resultados altamente competitivos. Esto respalda la utilidad del enfoque adoptado en este trabajo y valida la decisión de integrar el modelo dentro de una interfaz de predicción orientada a usuarios finales.

No obstante, como ocurre en la mayoría de los trabajos basados en aprendizaje profundo aplicado al ámbito médico, el modelo sigue presentando diversas limitaciones relacionadas principalmente con la variabilidad de las imágenes, la dificultad de detectar lesiones muy leves y la ausencia de un conjunto de prueba completamente

independiente. Estas limitaciones marcan el camino hacia posibles mejoras futuras, tanto en el diseño del modelo como en el tratamiento de los datos, con el objetivo de incrementar la robustez y la aplicabilidad del sistema en contextos reales.

5.6 Desarrollo de la interfaz gráfica

La interacción final con los modelos predictivos se ha implementado mediante una aplicación web desarrollada con el framework de código abierto Streamlit [43]. Esta herramienta permite transformar los scripts de procesamiento de datos en una interfaz de usuario interactiva y accesible, facilitando el uso de los modelos por parte del personal médico sin necesidad de conocimientos avanzados de programación.

La arquitectura de la interfaz se divide en dos módulos funcionales diferenciados, accesibles mediante un sistema de pestañas: predicción clínica de diabetes (datos tabulares) y detección de retinopatía diabética (imágenes).

5.6.1 Módulo de predicción de diabetes

Este módulo conecta el modelo de Red Neuronal Profunda (MLP) reentrenado con el dataset extendido de 100.000 registros. La interfaz se ha diseñado con dos modos de entrada de datos para adaptarse a distintos flujos de trabajo clínico.





Sistema de Predicción de Diabetes

 **Análisis de Sangre**  Imagen de Fondo de Ojo

Análisis de Sangre

Modelo: Deep Learning | Datos: Diabetes Prediction Dataset (100.000 pacientes)

Selecciona el método de entrada:

 Formulario manual  Subir archivo CSV

Datos del Paciente

Género	Female 	Historial de Fumador	No Info 
Edad	40,00  	BMI (Índice Masa Corporal)	27,00  
¿Hipertensión?	<input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel HbA1c (Hemoglobina)	5,50  
¿Enfermedad Cardíaca?	<input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel Glucosa en Sangre	140  
			

Ilustración 27 Vista general de la interfaz de usuario desarrollada con Streamlit.

5.6.1.1 Formulario de evaluación individual

Se ha implementado un formulario interactivo que recoge las variables predictoras críticas (Edad, BMI, HbA1c, Glucosa, etc.). A diferencia de interfaces básicas, este módulo gestiona la complejidad de los datos mixtos mediante:

- Selectores categóricos: Para variables cualitativas como “Género” o “Historial de fumador”, el sistema despliega menús intuitivos. Internamente, la aplicación utiliza los objetos codificadores (LabelEncoders) generados durante la fase de entrenamiento para transformar estas selecciones en los valores numéricos que la red neuronal requiere.

Datos del Paciente

Género Female <input checked="" type="radio"/> <input type="radio"/> Male <input type="radio"/> Other <input type="radio"/>	Historial de Fumador No Info
¿Enfermedad Cardíaca? <input checked="" type="radio"/> No <input type="radio"/> Sí	BMI (Índice Masa Corporal) 27,00 - +
	Nivel HbA1c (Hemoglobina) 5,50 - +
	Nivel Glucosa en Sangre 140 - +

Calcular Riesgo

Ilustración 28 Detalle de los componentes de selección categórica en el formulario.

- Validación de rangos: Los campos numéricos incluyen restricciones lógicas (por ejemplo, impidiendo valores negativos en la edad o niveles de glucosa imposibles) para minimizar errores humanos en la introducción de datos.

Edad 0,00 - +	BMI (Índice Masa Corporal) 26,99 - +
¿Hipertensión? <input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel HbA1c (Hemoglobina) 5,20 - +
¿Enfermedad Cardíaca? <input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel Glucosa en Sangre 140 - +

Calcular Riesgo

Ilustración 29 Detalle de los componentes de validación de rangos en el formulario.

- Indicadores binarios de comorbilidad: Se han integrado controles de opción dicotómica (Sí/No) para registrar antecedentes de hipertensión y enfermedades cardíacas. Estos selectores permiten una captura rápida de las preexistencias médicas, traduciendo la respuesta del usuario a formato binario (0 o 1) de manera transparente antes de la inferencia.

Datos del Paciente

Género	Female	Historial de Fumador	No Info
Edad	0,00	BMI (Índice Masa Corporal)	26,99
¿Hipertensión?	<input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel HbA1c (Hemoglobina)	5,20
¿Enfermedad Cardíaca?	<input checked="" type="radio"/> No <input type="radio"/> Sí	Nivel Glucosa en Sangre	140

Calcular Riesgo

Ilustración 30 Detalle de los indicadores binarios de comorbilidad.

Una vez introducidos los datos, el sistema normaliza las entradas utilizando el mismo escalador (StandardScaler) aplicado en el entrenamiento y presenta el resultado mediante un código de colores semafórico, facilitando la interpretación rápida del riesgo.

🔴 Análisis de Sangre 👁️ Imagen de Fondo de Ojo

🔴 Análisis de Sangre

Modelo: Deep Learning | Datos: Diabetes Prediction Dataset (100.000 pacientes)

Selecciona el método de entrada:

📄 Formulario manual
 📁 Subir archivo CSV

Datos del Paciente

Género <input type="text" value="Male"/>	Historial de Fumador <input type="text" value="current"/>
Edad <input type="text" value="62,00"/> - +	BMI (Índice Masa Corporal) <input type="text" value="34,80"/> - +
¿Hipertensión? <input type="radio"/> No <input checked="" type="radio"/> Sí	Nivel HbA1c (Hemoglobina) <input type="text" value="8,20"/> - +
¿Enfermedad Cardíaca? <input type="radio"/> No <input checked="" type="radio"/> Sí	Nivel Glucosa en Sangre <input type="text" value="240"/> - +

■ **Resultado: POSITIVO (Riesgo Alto)**

El modelo detecta patrones compatibles con diabetes.

Ilustración 31 Validación del sistema de alertas con un caso positivo simulado.

5.6.1.2 Procesamiento por lotes (CSV)

Para escenarios de cribado masivo, la interfaz permite la carga de archivos en formato .csv. El sistema implementa una capa de validación previa que verifica automáticamente si el archivo contiene las columnas obligatorias antes de procesarlo. Los resultados se visualizan en una tabla dinámica donde cada fila se colorea según el diagnóstico de la IA, permitiendo al especialista identificar rápidamente los casos de riesgo en listas extensas de pacientes. Adicionalmente, se permite la descarga del informe completo con las predicciones añadidas.



Sistema de Predicción de Diabetes

 [Análisis de Sangre](#)  [Imagen de Fondo de Ojo](#)

Análisis de Sangre

Modelo: Deep Learning | Datos: Diabetes Prediction Dataset (100.000 pacientes)

Selecciona el método de entrada:

 Formulario manual  Subir archivo CSV

Sube un CSV con columnas: gender, age, hypertension, heart_disease, smoking_history, bmi, HbA1c_level, blood_glucose_level

Arrastra tu archivo aquí



Drag and drop file here

Limit 200MB per file • CSV

Browse files

Ilustración 32 Módulo de carga masiva de datos en formato CSV.

🔴 **Análisis de Sangre** 📄 Imagen de Fondo de Ojo

🔴 Análisis de Sangre

Modelo: Deep Learning | Datos: Diabetes Prediction Dataset (100.000 pacientes)

Selecciona el método de entrada:

📄 Formulario manual 📁 Subir archivo CSV

Sube un CSV con columnas: gender, age, hypertension, heart_disease, smoking_history, bmi, HbA1c_level, blood_glucose_level

Arrastra tu archivo aquí

📁 Drag and drop file here
Limit 200MB per file • CSV Browse files

📄 prueba.csv 268.0B ✕

Informe de Lote

Positivos Detectados: **3**

Negativos Detectados: **2**

	Predicción IA	gender	age	hypertension	heart_disease	smoking_history	bmi	HbA1
0	🟢 SANO	Female	25.000000	0	0	never	22.500000	5.
1	🔴 DIABETES	Male	62.000000	1	1	current	34.800000	8.
2	🔴 DIABETES	Female	55.000000	1	0	former	29.100000	6.
3	🟢 SANO	Male	30.000000	0	0	No Info	24.000000	4.
4	🔴 DIABETES	Male	75.000000	1	1	former	38.500000	9.

Ilustración 33 Tabla de resultados del procesamiento por lotes.

5.6.2 Módulo de detección de retinopatía

El segundo módulo actúa como interfaz para la Red Neuronal Convolutiva (CNN). El usuario puede cargar retinografía (imágenes de fondo de ojo) en formatos estándar (JPG, PNG).

El flujo de procesamiento en la interfaz es el siguiente:

1. Previsualización: La imagen cargada se muestra en pantalla para confirmación visual.

2. Preprocesamiento en tiempo real: Antes de la inferencia, la aplicación redimensiona la imagen a 224x224 píxeles y normaliza sus valores, replicando el tratamiento de datos realizado durante el entrenamiento del modelo.
3. Inferencia y diagnóstico: El modelo emite una probabilidad de patología. Si esta supera el umbral de decisión establecido (0.5), el sistema alerta de la presencia de signos compatibles con retinopatía diabética.



Ilustración 34 Interfaz del módulo de diagnóstico por imagen para detección de retinopatía diabética.

Sistema de Predicción de Diabetes

 Análisis de Sangre  Imagen de Fondo de Ojo

Detección de Retinopatía Diabética

Modelo: CNN (Análisis de Imágenes)

Sube una retinografía para analizar:

Sube imagen (JPG/PNG)



Drag and drop file here

Limit 200MB per file • JPG, JPEG, PNG

Browse files



0bf37ca3156a.png 5.0MB




Imagen analizada

Diagnóstico:


 POSITIVO: Retinopatía Detectada

Ilustración 35 Validación del módulo de detección de retinopatía diabética con un caso positivo.



CAPÍTULO 6: CONCLU- SIONES Y TRABAJOS FUTUROS

6.1 Conclusiones

El presente Trabajo de Fin de Grado ha demostrado la viabilidad de utilizar técnicas de inteligencia artificial para apoyar el diagnóstico temprano de la diabetes y sus complicaciones asociadas. Para ello se han desarrollado dos modelos independientes: una red neuronal para la predicción de diabetes a partir de datos clínicos numéricos y una red convolucional para la detección de retinopatía diabética en imágenes de fondo de ojo. Ambos modelos han sido integrados en una interfaz interactiva que permite al usuario introducir datos o imágenes y obtener una predicción inmediata.

En el caso del modelo basado en datos numéricos, se ha comprobado que una red neuronal simple es capaz de capturar patrones asociados a la presencia de diabetes utilizando un conjunto reducido de parámetros clínicos. Las métricas obtenidas durante la evaluación, junto con la matriz de confusión y el análisis de los errores más frecuentes, evidencian un rendimiento consistente y útil como herramienta de apoyo.

Por otro lado, el modelo convolucional desarrollado desde cero ha logrado una precisión del 95% en el conjunto binario de imágenes reorganizadas, mostrando un desempeño equilibrado entre las clases con y sin retinopatía. A pesar de su sencillez arquitectónica, la CNN ha demostrado una capacidad notable para identificar patrones visuales relevantes, validando así la elección del enfoque y la metodología aplicada en la preparación del dataset.

La aplicación final desarrollada en Streamlit permite integrar estos modelos en un entorno accesible para el usuario, mostrando la predicción acompañada de probabilidades y asegurando que el procesamiento de datos e imágenes siga el mismo pipeline utilizado durante el entrenamiento. Esto demuestra que el trabajo no solo se limita al ámbito académico, sino que además tiene potencial para evolucionar hacia una herramienta de utilidad real en un entorno clínico supervisado.

En términos generales, los resultados obtenidos permiten concluir que la combinación de aprendizaje automático basado en datos tabulares y aprendizaje profundo aplicado a imágenes constituye un enfoque sólido para apoyar el diagnóstico temprano. No obstante, se reconoce que las predicciones deben interpretarse siempre como un complemento y no como un sustituto de la evaluación médica profesional.

6.2 Líneas de trabajo futuras

De cara a futuras ampliaciones del proyecto, existen diversas líneas de trabajo que permitirían mejorar tanto el rendimiento de los modelos como su aplicabilidad en contextos reales. En primer lugar, sería conveniente ampliar y refinar el conjunto de datos utilizado, incorporando imágenes procedentes de diferentes dispositivos, condiciones de iluminación y poblaciones. Esto no solo aumentaría la capacidad de generalización del modelo convolucional, sino que también permitiría disponer de un conjunto de prueba realmente independiente, con el que evaluar de forma más rigurosa el comportamiento del sistema fuera del entorno de entrenamiento.

Otra posible mejora consiste en la incorporación de técnicas avanzadas como el transfer-learning. El uso de arquitecturas preentrenadas, tales como EfficientNet, ResNet o Inception, podría ofrecer mejoras significativas frente al modelo convolucional desarrollado desde cero, especialmente en la detección de lesiones leves o en imágenes de baja calidad. Este enfoque permitiría aprovechar características ya aprendidas a partir de grandes bases de datos de imágenes, facilitando un aprendizaje más robusto y eficiente.

Asimismo, constituye un aspecto relevante la implementación de técnicas de interpretabilidad como Grad-CAM o los mapas de saliencia, que proporcionarían información visual sobre qué regiones de las imágenes influyen en la decisión del modelo. Este tipo de herramientas resulta especialmente valioso en el ámbito médico, pues aporta transparencia al proceso y facilita que los profesionales puedan interpretar y validar las predicciones generadas por el sistema.

En cuanto a la arquitectura de la red, sería interesante explorar variaciones más profundas y complejas que permitan captar patrones visuales de mayor detalle. La optimización de hiperparámetros, el uso de regularización adaptativa o la experimentación con optimizadores alternativos podrían contribuir a un rendimiento superior y a una mayor estabilidad durante el proceso de aprendizaje.

Desde el punto de vista práctico, una validación clínica con datos procedentes de consultas reales representaría un paso esencial para evaluar la utilidad del sistema en entornos profesionales. La comparación entre las predicciones del modelo y la valoración de especialistas permitiría identificar fortalezas, limitaciones y posibles oportunidades de mejora.

Finalmente, la plataforma desarrollada constituye una base ideal para evolucionar hacia un sistema más amplio de apoyo al diagnóstico. Además de perfeccionar la interfaz para hacerla más intuitiva y accesible, podría integrarse la posibilidad de incluir nuevos modelos entrenados para detectar otras enfermedades, no solo aquellas relacionadas directamente con la diabetes. Por ejemplo, sería viable desarrollar módulos adicionales basados en IA capaces de identificar patologías respiratorias a partir de radiografías, clasificar cáncer de piel mediante imágenes dérmicas o predecir riesgos cardiovasculares utilizando datos clínicos tabulares. De esta forma, la herramienta podría transformarse en una plataforma modular que permita añadir y actualizar modelos de manera independiente, ampliando progresivamente su alcance y convirtiéndose en un sistema integral de diagnóstico asistido por inteligencia artificial.

CAPÍTULO 7: BIBLIO- GRAFÍA

UNIVERSITAS Miguel Hernández

- [1] Parlamento Europeo. (2023, 10 octubre). *¿Qué es la inteligencia artificial y cómo se usa?* <https://www.europarl.europa.eu/topics/es/article/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa>
- [2] Gobierno de España. (2023, 19 abril). *¿Qué es la inteligencia artificial (IA)? Plan de Recuperación, Transformación y Resiliencia.* <https://planderecuperacion.gob.es/noticias/que-es-inteligencia-artificial-ia-prtr>
- [3] IBM. (s.f.). *¿Qué es la inteligencia artificial en medicina?* <https://www.ibm.com/es-es/topics/artificial-intelligence-medicine>
- [4] Sanofi. (2022, 27 junio). *Inteligencia artificial y salud: una alianza que avanza con paso firme.* <https://pro.campus.sanofi/es/actualidad/articulos/inteligencia-artificial-salud>
- [5] MedlinePlus. (2023, 4 diciembre). *Diabetes tipo 2.* <https://medlineplus.gov/spanish/ency/article/001214.htm>
- [6] Centros para el Control y la Prevención de Enfermedades. (2022, 11 octubre). *Factores de riesgo de la diabetes.* <https://www.cdc.gov/diabetes/es/risk-factors/factores-de-riesgo-de-la-diabetes.html>
- [7] Mayo Clinic. (2023, 19 octubre). *Retinopatía diabética: síntomas y causas.* <https://www.mayoclinic.org/es/diseases-conditions/diabetic-retinopathy/symptoms-causes/syc-20371611>
- [8] Academia Americana de Oftalmología. (s.f.). *Retinopatía diabética.* <https://www.aaopt.org/salud-ocular/enfermedades/retinopatia-diabetica>
- [9] Revista Diabetes. (s.f.). *Inteligencia artificial y diabetes.* <https://www.revistadiabetes.org/tecnologia/inteligencia-artificial-y-diabetes/>
- [10] Instituto de Investigación Sanitaria La Fe. (2023, 10 noviembre). *La IA como herramienta para detectar y controlar la diabetes y la retinopatía diabética.* <https://www.iislafe.es/es/sociedad/blog/5/la-ia-como-herramienta-para-detectar-y-controlar-la-diabetes-y-la-retinopatia-diabetica>
- [11] Revista Diabetes. (s.f.). *Intervención de la inteligencia artificial en la diabetes.* <https://www.revistadiabetes.org/tecnologia/intervencion-de-la-inteligencia-artificial-en-la-diabetes/>
- [12] Wikipedia. (s.f.). *Red neuronal artificial.* Wikipedia. https://es.wikipedia.org/wiki/Red_neuronal_artificial
- [13] Xeridia. (2023, 24 mayo). *Redes neuronales artificiales: qué son y cómo se entrenan (parte I).* <https://www.xeridia.com/blog/redes-neuronales-artificiales-que-son-y-como-se-entrenan-parte-i>
- [14] Wikipedia. (s.f.). *Red neuronal convolucional.* Wikipedia. https://es.wikipedia.org/wiki/Red_neuronal_convolutional

- [15] MathWorks. (s.f.). *Red neuronal convolucional*. <https://es.mathworks.com/discovery/convolutional-neural-network.html>
- [16] APD. (2023, 4 mayo). *Aplicaciones de la inteligencia artificial en medicina*. <https://www.apd.es/aplicaciones-inteligencia-artificial-en-medicina/>
- [17] Invox Medical. (2023, 21 marzo). *Usos de la inteligencia artificial para el diagnóstico médico*. <https://www.invoxmedical.com/blog/usos-de-la-inteligencia-artificial-para-el-diagnostico-medico>
- [18] Herrera, G., & De-la-Peña, D. (2022). *Aplicaciones del aprendizaje automático en salud*. *Revista Médica Clínica Las Condes*, 33 (6), 625–632. <https://www.elsevier.es/es-revista-revista-medica-clinica-las-condes-202-articulo-aplicaciones-aprendizaje-automatico-salud-S0716864022001195>
- [19] Campus HealthTech. (2023, 6 noviembre). *Deep learning en el análisis de imágenes médicas*. <https://campushealthtech.com/blog/deep-learning-en-el-analisis-de-imagenes-medicas/>
- [20] Impulso06. (2023, 15 septiembre). *¿Podrá la inteligencia artificial en medicina reemplazar a los médicos?* <https://impulso06.com/podra-la-inteligencia-artificial-en-medicina-reemplazar-a-los-medicos/>
- [21] CIO. (2018, 12 julio). *Nueve mitos sobre machine learning*. <https://www.cio.com/article/2073692/nueve-mitos-sobre-machine-learning.html>
- [22] Universidad Internacional de Andalucía. (2023, 9 octubre). *Inteligencia artificial en la medicina: el futuro de la salud*. <https://www.unia.es/vida-universitaria/blog/inteligencia-artificial-en-la-medicina-el-futuro-de-la-salud>
- [23] Murugesan, B., Shenoy, P., & Sundararajan, V. (2023). *Artificial intelligence in early diagnosis of diabetes: a review*. *Frontiers in Medicine*, 10, 10946312. <https://doi.org/10.3389/fmed.2023.10946312>
- [24] Universidad Iberoamericana de Colombia. (s.f.). *Técnicas de machine learning*. <https://www.ibero.edu.co/blog/articulos/tecnicas-de-machine-learning>
- [25] Oftálica. (2022, 21 abril). *Retinografía en diabetes: prueba de imágenes en diagnóstico ocular*. <https://www.oftalica.com/retinografia-en-diabetes-prueba-de-imagenes-en-diagnostico-ocular/>
- [26] Zambrano, F. (2022). *Inteligencia artificial aplicada al diagnóstico de retinopatía diabética*. *Archivos de Oftalmología de Buenos Aires*, 97 (1), 34–38. <https://archivosoftalmologia.com.ar/index.php/revista/article/view/142/207>
- [27] Amazon Web Services. (s.f.). *¿Qué es Python?* AWS. Recuperado el 26 de mayo de 2025, de <https://aws.amazon.com/es/what-is/python/>
- [28] OpenWebinars. (s.f.). *Qué es Jupyter Notebook: una herramienta para ciencia de datos*. Recuperado de <https://openwebinars.net/blog/jupyter-notebook/>

- [29] Anaconda Software Distribution. (2020). *Anaconda Documentation*. Retrieved from <https://docs.anaconda.com/>
- [30] DataScientest. (s.f.). *NumPy: la biblioteca Python imprescindible*. <https://datascientest.com/es/numpy-la-biblioteca-python>
- [31] DataScientest. (s.f.). *Pandas en Python: ¿qué es esta biblioteca de análisis de datos?* DataScientest. <https://datascientest.com/es/pandas-python>
- [32] DataScientest. (s.f.). *Scikit-learn: descubre la biblioteca Python*. <https://datascientest.com/es/scikit-learn-descubre-la-biblioteca-python>
- [33] IONOS. (s. f.). *Python Multiprocessing: Ejecución en paralelo con Python*. IONOS Digital Guide. <https://www.ionos.es/digitalguide/paginas-web/desarrollo-web/python-multiprocessing/>
- [34] DataScientest. (2023). *Matplotlib: todo lo que tienes que saber sobre la librería Python de Dataviz*. <https://datascientest.com/es/todo-sobre-matplotlib>
- [35] Arsys. (s. f.). *¿Qué es Visual Studio Code y cuáles son sus ventajas?* Arsys. Recuperado el 26 de mayo de 2025, de <https://www.arsys.es/blog/que-es-visual-studio-code-y-cuales-son-sus-ventajas>
- [36] UNIR Formación Profesional. (s.f.). *Planificación de proyectos*. <https://unirfp.unir.net/revista/empresa/planificacion-de-proyectos/>
- [37] Miro (s. f.). *¿Qué es WBS?* Recuperado de <https://miro.com/es/gestion-proyectos/que-es-wbs/>
- [38] Asana. (s.f.). *Fundamentos del diagrama de Gantt*. Recuperado de <https://asana.com/es/resources/gantt-chart-basics>
- [39] UCI Machine Learning. (s. f.). *Pima Indians Diabetes Database*. Kaggle. <https://www.kaggle.com/datasets/uciml/pima-indians-diabetes-database>
- [40] Barrios Arce, J. I. (2019, 26 de julio). *La matriz de confusión y sus métricas*. Juan Barrios. Recuperado de <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/>
- [41] Amazon Web Services, Inc. (2024). *¿Qué es una red neuronal?* Recuperado de <https://aws.amazon.com/es/what-is/neural-network/>
- [42] Codificando Bits. (s. f.). *¿Qué es una Red Neuronal?* Recuperado de <https://codificandobits.com/blog/que-es-una-red-neuronal/>
- [43] Streamlit Inc. (2023). *Streamlit Documentation*. Recuperado de <https://docs.streamlit.io/>