




NeuroMedX: Aplicación móvil para el monitoreo médico personalizado NeuroMedX: Mobile application for personalized medical monitoring

M.G. Pineda-Arizmendi ^a, A. Alvaro-López ^a, J. Corona-Mondragón ^a

^a Tecnológico Nacional de México/Tecnológico de Estudios Superiores de Tianguistenco, División de Ingeniería en Sistemas Computacionales. Carretera Tenango, Santiago-La Marquesa 22, 52650 Santiago Tilapa, Estado de México, México.

Resumen

El presente artículo expone el desarrollo de NeuroMedX, una aplicación móvil que incorpora técnicas de inteligencia artificial con el propósito de optimizar la gestión y el seguimiento de la salud personal, al tiempo que facilita la comunicación entre médicos y pacientes. La aplicación permite el registro local de signos vitales y sincroniza automáticamente la información con una plataforma web para su verificación. Se implementaron dos redes neuronales independientes de tipo *Multilayer Perceptron* (MLP): la primera destinada a la clasificación de 14 enfermedades y la segunda al reconocimiento de 23 medicamentos mediante el uso de *tokens*. El modelo de enfermedades alcanzó una precisión del 91% con una pérdida de 0.1557 tras 400 épocas de entrenamiento, mientras que el modelo de medicamentos obtuvo una precisión del 89.86% con una pérdida de 0.249. Ambos modelos fueron integrados en dispositivos móviles mediante TensorFlow Lite, mostrando estabilidad operativa y una tasa de error semántico aproximada del 12%, atribuida a la complejidad de los datos locales. Los resultados preliminares evidencian la existencia de una base de datos sólida y un sistema técnicamente viable, con un potencial significativo para fortalecer la telemedicina y el monitoreo preventivo en tiempo real.

Palabras Clave: Inteligencia artificial, redes neuronales, aplicación médica, telemedicina, monitoreo, firebase.

Abstract

This article presents the development of NeuroMedX, a mobile application that incorporates artificial intelligence techniques with the aim of optimizing personal health management and monitoring, while facilitating communication between doctors and patients. The application allows local recording of vital signs and automatically synchronizes the information with a web platform for verification. Two independent Multilayer Perceptron (MLP) neural networks were implemented: the first for the classification of 14 diseases and the second for the recognition of 23 medications through the use of tokens. The disease model achieved 91% accuracy with a loss of 0.1557 after 400 training epochs, while the medication model achieved 89.86% accuracy with a loss of 0.249. Both models were integrated into mobile devices using TensorFlow Lite, showing operational stability and an approximate semantic error rate of 12%, attributed to the complexity of the local data. The preliminary results demonstrate the existence of a robust database and a technically viable system with significant potential to strengthen telemedicine and real-time preventive monitoring.

Keywords: Artificial intelligence, neural networks, medical application, telemedicine, monitoring, firebase.

1. Introducción

La integración de tecnologías móviles, sistemas de conectividad avanzada y algoritmos de Inteligencia Artificial (IA) está transformando profundamente el cuidado de la salud. Las plataformas de telemedicina y los sistemas de monitoreo remoto permiten la captura continua de datos fisiológicos, facilitando la detección temprana de anomalías y reduciendo la carga sobre los servicios sanitarios. Estas plataformas médicas digitales funcionan como ecosistemas que integran historia

clínica electrónica, teleconsulta, y herramientas de análisis, con el objetivo de mejorar la eficiencia y calidad de la detección (DiriCloud, 2025). Su capacidad para aprovechar los datos clínicos, dispositivos portátiles e IA permite automatizar decisiones y obtener información procesable para optimizar tratamientos mediante el estudio de la eficiencia (Cortes, 2020).

*Autora para la correspondencia: maria_pa@test.edu.mx

Correos electrónicos: maria_pa@test.edu.mx (M.G. Pineda-Arizmendi), alexander_2223024@test.edu.mx (A. Alvaro-López), jocelyn_2223021@test.edu.mx (J. Corona Mondragón).

Historial del manuscrito: recibido el 25/11/2025, última versión-revisada recibida el 06/02/2026, aceptado el 26/02/2025, publicado el 06/04/2026. DOI:<https://doi.org/10.29057/icbi.v14iEspecial2.16697>



El crecimiento exponencial de los datos clínicos ha vuelto indispensable la interoperabilidad entre sistemas de información en salud. Mientras que décadas atrás un médico recibía un número limitado de parámetros por paciente, en la actualidad se gestionan miles de datos provenientes tanto de entornos hospitalarios como de monitoreo remoto, lo que exige plataformas tecnológicas capaces de procesar y analizar grandes volúmenes de información de forma eficiente.

Paralelamente, la percepción del personal médico respecto al uso de la inteligencia artificial ha evolucionado de manera positiva. Entre 2023 y 2024, el entusiasmo por la adopción de estas tecnologías aumentó del 30 % al 35 %, mientras que las principales preocupaciones asociadas a su uso disminuyeron, reflejando una mayor aceptación de la IA como herramienta de apoyo clínico (American Medical Association, 2025).

A pesar de sus beneficios intrínsecos, la integración de la IA en el sector salud conlleva riesgos críticos que deben ser gestionados. Entre ellos destacan los sesgos algorítmicos, la opacidad en los procesos de decisión (falta de transparencia), la dependencia crítica de datos de alta calidad y las vulnerabilidades en la privacidad del paciente. Como sostiene Jalife (2024), estos desafíos exigen un marco de regulación robusto y una supervisión especializada que garantice el uso ético y seguro de estas tecnologías en la práctica clínica. Frente a estos desafíos, las plataformas médicas inteligentes basadas en redes neuronales representan una alternativa prometedora para así mejorar el monitoreo clínico y apoyar la detección temprana de las condiciones médicas de cada paciente. Una plataforma médica es un ecosistema digital integral, está diseñada para ayudar a los profesionales del área de salud a brindar una atención eficiente y de alta calidad. Integra herramientas se unifican en un sistema que satisface las necesidades de los pacientes, médicos, administradores y algunas otras partes interesadas. El sistema abarca desde la telemedicina hasta la historia clínica electrónica (HCE), también incluye soluciones de gestión (DiriCloud, 2025).

El presente trabajo propone el desarrollo de NeuroMedX una aplicación de monitoreo médico sustentada en inteligencia artificial y redes neuronales, orientada a proporcionar seguimiento continuo de la salud y apoyar la toma de decisiones clínicas. Su implementación contribuye al avance hacia sistemas de salud más personalizados preventivos y eficientes, alineados con las demandas actuales de digitalización e innovación sustentable.

2. Antecedentes

Como señala Aracena (2022), la integración de la inteligencia artificial (IA) y el aprendizaje automático (AA) ha propiciado una transformación paradigmática en el sector salud. Esta convergencia tecnológica no solo ha optimizado el análisis de grandes volúmenes de datos médicos, sino que ha fortalecido sustancialmente los procesos de toma de decisiones clínicas, permitiendo diagnósticos más precisos y personalizados el cual señala que los modelos basados en árboles de decisión, máquinas de soporte vectorial y redes neuronales han mostrado altos niveles de eficacia en tareas de diagnóstico, predicción de mortalidad intrahospitalaria, detección de inasistencia de pacientes y análisis de imágenes

médicas. El estudio destacó que la incorporación de estas tecnologías permitió alcanzar niveles de precisión cercanos al 98%, en determinados escenarios clínicos, evidenciando el potencial del aprendizaje automático para fortalecer la medicina predictiva y personalizada. Además, enfatiza la importancia de considerar los principios éticos de transparencia, equidad y responsabilidad en el desarrollo de sistemas inteligentes aplicados al cuidado de la salud. En concordancia con estos avances, el proyecto retomó dichos avances tecnológicos y los orientó al desarrollo de una aplicación móvil basada en IA para el monitoreo y seguimiento de la salud personal, con el propósito de facilitar la comunicación médico-paciente y promover la prevención mediante análisis predictivo.

El monitoreo remoto de pacientes (RPM) se ha posicionado como una herramienta esencial en la atención sanitaria contemporánea, especialmente en el manejo de enfermedades crónicas o agudas fuera del entorno hospitalario. En su estudio, Shaik (2023) realizó una revisión del estado actual y los desafíos del uso de la Inteligencia Artificial (IA) en los sistemas de Monitoreo Remoto de Plagas (RPM, por sus siglas en inglés). El autor señala que los modelos tradicionales, al depender de la supervisión manual, presentan limitaciones críticas en términos de eficiencia y escalabilidad. En contraste, los autores señalaron que el uso de IA facilitó la automatización de la recolección de datos fisiológicos, la detección de anomalías en tiempo real y la respuesta rápida ante deterioros clínicos. Además, el artículo destacó retos relevantes como la interoperabilidad de plataformas, la calidad y variabilidad de los datos, la seguridad del paciente, la transparencia del algoritmo y la necesidad de validar modelos de entornos reales. Por lo tanto, destacó la viabilidad técnica y clínica del enfoque basado en IA para RMP, estableciendo una base conceptual sólida para el desarrollo del presente proyecto, que propuso una aplicación móvil con IA para el monitoreo y seguimiento de la salud personal.

El estudio difundido por SaludByDiaz (2025) destaca la creciente implementación de métodos de aprendizaje profundo (Deep Learning) en el análisis de señales fisiológicas y la evaluación de imágenes médicas para la detección temprana de patologías. La investigación subraya que la irrupción de tecnologías de conectividad avanzada —tales como 5G, URLLC (Ultra-Reliable Low Latency Communications o comunicaciones de baja latencia y ultra confiables), eMBB (Enhanced Mobile Broadband o banda ancha móvil mejorada) y mMTC (Massive Machine Type Communications o comunicaciones masivas de tipo máquina)— facilita la transmisión de datos en tiempo real. Esta infraestructura permite extender los servicios de telemedicina a zonas rurales y optimizar la gestión económica de la salud al reducir las barreras geográficas y técnicas. Asimismo, se resalta la capacidad del aprendizaje profundo para procesar datos estructurados y no estructurados, integrando análisis de proteómica, vías biológicas y transformación de ondículas discretas (Discrete Wavelet Transform) para alcanzar una precisión diagnóstica superior a las técnicas tradicionales. En consecuencia, se demuestra que la convergencia de redes neuronales profundas, Big Data fisiológico y conectividad móvil constituye un paradigma viable hacia sistemas de

monitoreo proactivos y ubicuos, con aplicaciones directas en el desarrollo de soluciones móviles.

La investigación de Alom (2025) introdujo un modelo de red neuronal profunda denominado DNBCD (Deep Network for Breast Cancer Detection), diseñado para la detección automatizada y precisa de cáncer de mama mediante imágenes histopatológicas y ecográficas. Basado en la arquitectura DenseNet-121 y fundamentado en el aprendizaje por transferencia (Transfer Learning), el modelo integra técnicas de normalización, aumento de datos (Data Augmentation) y métodos de interpretabilidad como Grad-CAM. Los resultados experimentales demostraron un alto rendimiento, alcanzando precisiones del 93.97% en el conjunto de datos BreakHis-400x y del 89.87% en el conjunto de datos BUSI. El énfasis en la aplicabilidad del algoritmo favorece la confianza del personal clínico al transparentar la toma de decisiones del sistema. Este antecedente resultó relevante, derivado que muestra tanto la viabilidad de aplicar redes neuronales profundas explicables en contextos médicos como los retos inherentes a la integración de algoritmos de IA en la práctica clínica. En conjunto con los antecedentes ya revisados demuestran que la IA, el AA y el aprendizaje profundo representan tecnologías consolidadas y de alto potencial en la gestión y monitoreo de la salud. Estos avances sustentan la pertinencia del presente proyecto, que busca desarrollar una aplicación móvil capaz de analizar datos fisiológicos mediante redes neuronales y brindar un monitoreo continuo a la prevención y al apoyo en la toma de decisiones clínicas.

3. Contribución Tecnológica

El desarrollo de la aplicación médica *NeuroMedX* con capacidades neuronales representa una contribución significativa en los ámbitos tecnológico, científico y social. Desde la perspectiva científica, esta propuesta permite explorar el potencial del aprendizaje automático aplicado en el procesamiento local de datos biomédicos, facilitando la toma de decisiones médicas mediante análisis más rápidos y personalizados. A nivel tecnológico, la utilización de frameworks como Flutter y TensorFlow Lite proporciona una plataforma robusta y eficiente para el desarrollo de multiplataforma de aplicaciones móviles inteligentes, capaces de funcionar incluso sin conexión constante a internet, lo que aumenta su usabilidad.

4. Contribución Social

La aplicación favorece el empoderamiento del paciente al ofrecerle un seguimiento continuo y personalizado de su estado de salud, así como la comunicación directa y segura con médicos profesionales a través de una plataforma web asociada. Frente a los desafíos actuales del sistema de salud, caracterizados por la saturación debido a las enfermedades crónicas y la fragmentación de registros médicos, *NeuroMedX* se presenta como una herramienta innovadora que contribuye a mejorar la atención preventiva y el control remoto, reduciendo la necesidad de hospitalizaciones innecesarias si fuera el caso.

De acuerdo con el *Informe sobre la Salud Digital Global*, el uso de tecnologías inteligentes en salud puede reducir hasta en

un 30 % las hospitalizaciones evitables y optimizar los recursos clínicos mediante la detección temprana de anomalías. La literatura reciente también destaca que la integración de IA en plataformas móviles permite adaptar los modelos predictivos a características individuales incrementando la precisión y eficiencia del monitoreo de pacientes (World Health Organization, 2021). Por estas razones, *NeuroMedX* no solo por su valor innovador y tecnológico, sino también por su impacto potencial en la mejora del sistema sanitario. Además, contribuye a la democratización del acceso a herramientas digitales de salud, especialmente en contextos donde la conectividad o infraestructura médica son limitadas, alineándose con las tendencias globales hacia servicios de salud más personalizados, accesibles y eficientes.

5. Marco teórico

A continuación, se describen algunos conceptos medulares de este proyecto como lo son:

5.1 Inteligencia artificial en la salud.

La Inteligencia Artificial (IA) ha emergido como una herramienta transformadora en el sector salud, gracias a su capacidad para analizar grandes volúmenes de datos clínicos y apoyar procesos diagnósticos, predictivos y decisionales. Estudios recientes demuestran que modelos de aprendizaje profundo pueden igualar o superar el desempeño humano en tareas especializadas, como la interpretación de imágenes médicas en dermatología y radiología (Esteve, y otros, 2021). Además, la IA permite la automatización de funciones como la estratificación del riesgo clínico y la monitorización continua del paciente, lo que incrementa la eficiencia y precisión en los sistemas sanitarios (Topol, 2021). Sin embargo, persisten retos importantes relacionados con la calidad y sesgo de los datos, la explicabilidad de los modelos, los aspectos éticos y el cumplimiento normativo que deben ser abordados para su integración segura y eficaz.

5.2 Big data en la salud.

El concepto de Big Data se sostiene en la gestión y análisis de grandes volúmenes de información heterogénea, generada a alta velocidad y con un enfoque en la veracidad y valor de los datos. En el ámbito sanitario, Big Data integra fuentes diversas como registros electrónicos de salud, dispositivos biomédicos portátiles, estudios genómicos y datos de telemedicina. Este ecosistema posibilita la detección temprana de enfermedades, la optimización de tratamientos y la elaboración de modelos predictivos robustos que impulsan la medicina personalizada y el monitoreo remoto (Mayer-Schönberger & Cukier, 2013). La sinergia entre Big Data e IA abre nuevas fronteras para la analítica predictiva que sustenta sistemas inteligentes de salud.

5.3 Aplicaciones móviles en salud (m-Health)

Las aplicaciones móviles para el cuidado de la salud han revolucionado la gestión biomédica y el seguimiento remoto de pacientes. Reconocidas por la Organización Mundial de la

Salud como herramientas clave, las soluciones m-Health facilitan la medición constante de signos vitales, la adherencia a tratamientos y la comunicación inmediata entre paciente y profesional sanitario. La incorporación de inteligencia artificial en estas aplicaciones potencia análisis instantáneos como predicciones personalizadas y alertas tempranas, aunque muchas aún dependen de conexión constante para operar eficazmente. Frameworks modernos como Flutter habilitan el desarrollo ágil y multiplataforma, acelerando la implementación de interfaces atractivas (Flutter, 2024).

5.4 Plataformas web y ecosistemas integrados de salud digital.

La interoperabilidad entre aplicaciones móviles, sensores biomédicos y plataformas web genera ecosistemas digitales de salud robustos y eficientes. Las plataformas web se apoyan en frameworks modernos como React.js y Node.js, que permiten crear dashboards interactivos con acceso a historiales médicos, alertas automatizadas y comunicación bidireccional entre paciente y médico. El uso de servicios como Firebase garantiza sincronización en tiempo real, autenticación segura y almacenamiento confiable, elementos esenciales en sistemas que manejan datos sensibles y requieren alta disponibilidad (Firebase, 2025 a). Estos ecosistemas digitales contribuyen a reducir la fragmentación de la información clínica y promueven una atención médica más integrada y personalizada.

5.5 IA embebida y privacidad de datos.

La ejecución de modelos de IA directamente en dispositivos móviles o computación periférica presenta ventajas relevantes para el sector salud, como la reducción de latencia en respuestas, mayor privacidad al evitar la transmisión de datos sensibles y funcionalidad en entornos con conectividad limitada (Lane, 2015). TensorFlow Lite se posiciona como la plataforma líder para optimizar y desplegar modelos de aprendizaje automático en dispositivos con recursos limitados, empleando técnicas como la cuantización y poda para conservar precisión minimizando el tamaño del modelo (TensorFlow, 2024). Esta estrategia potencia aplicaciones locales inteligentes para monitoreo y diagnóstico sin comprometer la seguridad ni la experiencia del usuario.

6. Problemática

Los sistemas de salud contemporáneos enfrentan una creciente presión debido al aumento de enfermedades crónicas, la limitada disponibilidad de infraestructura médica y la saturación de servicios clínicos. Según la Organización Panamericana de la Salud (Organización Panamericana de la Salud, 2022), las enfermedades no transmisibles representan aproximadamente herramientas preventivas y de monitoreo continuo que apoyen la detección temprana y el seguimiento personalizado del paciente. A pesar de los avances recientes en telemedicina y salud digital, una parte importante de las aplicaciones disponibles presentan limitaciones significativas: dependen de una conectividad constante a internet y carecen de algoritmos de análisis inteligente integrados o no ofrecen un mecanismo eficiente para procesar datos biométricos de manera local. Esto reduce su eficacia en contextos con baja

conectividad y restringe su capacidad para generar predicciones o alertas útiles para el usuario.

Adicionalmente, persiste una brecha crítica en la comunicación paciente-médico fuera del entorno hospitalario. Los registros clínicos suelen permanecer fragmentados entre múltiples plataformas y muchos pacientes no cuentan con medios autorizados para compartir información fisiológica actualizada, lo que dificulta el seguimiento oportuno y puede retrasar intervenciones preventivas. En este contexto surge la necesidad de una solución integral que permita la adquisición de datos fisiológicos mediante sensores, el procesamiento local mediante modelos neuronales y la sincronización segura con la nube, facilitando así la colaboración entre paciente y profesional de la salud. El proyecto de aplicación médico neuronal busca responder a esta problemática al proporcionar una plataforma móvil accesible que unifica captura de datos, análisis inteligente y comunicación en un solo sistema funcional, además de que el paciente pueda realizar consultas sobre medicamentos de su interés.

7. Metodología o método

El presente proyecto *NeuroMedX* se basa en el desarrollo de una aplicación móvil inteligente para monitoreo médico personalizado, donde la pieza central es un sistema de inteligencia artificial que utiliza dos redes neuronales artificiales Multilayer Perceptron (MLP) independientes, con soporte tecnológico y arquitectura robusta para garantizar precisión y eficiencia en el análisis de síntomas predicción de enfermedades y consulta de medicamentos. La metodología siguió un enfoque iterativo y combinado, estructurado en cinco fases principales:

Fase 1: Diseño de la interfaz de usuario.

Se definieron los requerimientos funcionales y no funcionales de la aplicación móvil para paciente y del portal web para el médico. En la app móvil se implementaron pantallas para registro, captura manual (y futura automática) de signos vitales, historial de registros y sistema de notificaciones. El portal web médico incluye dashboard con acceso a fichas de pacientes, gráficos de evolución, historial médico y recepción automática de alertas. La app móvil fue desarrollada en Flutter, con integración de Google Fonts, animaciones Lottie y Awesome Notifications para gestión de alertas. La plataforma web fue construida con React.js y Node.js para una comunicación eficiente con el backend y una interfaz dinámica.

Fase 2: Entrenamiento y conversión del modelo de inteligencia artificial.

Se desarrollaron dos redes neuronales artificiales independientes mediante TensorFlow 2x una para análisis de síntomas y predicción de enfermedades y otra para la identificación y consulta de medicamentos. La separación responde a que cada red aborda dominios semánticos diferentes, mejorando la precisión, facilitando el entrenamiento, mantenimiento y desempeño en dispositivos móviles. Ambas redes fueron entrenadas con conjuntos de datos correspondientes, utilizando técnicas de procesamiento como codificación categórica, normalización, tokenización, y embeddings. La validación fue a partir de particiones de

entrenamiento y prueba, evaluando métricas de precisión, exactitud y pérdida categórica media. Luego se convirtieron a formato TensorFlow Lite (TFLite) optimizado para dispositivos móviles mediante cuantización de pesos, logrando reducción del tamaño y mejora en rendimiento sin degradar la calidad.

Fase 3: Integración local en la aplicación móvil.

Los modelos fueron integrados en la aplicación de Flutter mediante el paquete `tflite_flutter` para carga e inferencia. Se implementaron funciones de procesamiento de entrada, gestión de inferencias simultáneas y manejo de errores. La ejecución se realiza localmente en el dispositivo para preservar la privacidad y operar sin conexión permanente. Las pruebas iniciales mostraron estabilidad, con una tasa de error aproximada del 60% en interpretación semántica.

Fase 4: Sincronización segura y comunicación en tiempo real.

Se desarrolló un backend basado en servicios RESTful y Firebase para sincronización de datos biométricos y predicciones. El portal web permite acceso controlado al historial y alertas para profesionales, mientras que el sistema de notificación inmediata refuerza la supervisión remota y la toma de decisiones oportuna.

Fase 5: Validación funcional y planificación para extensiones.

Se verificó la funcionalidad general del sistema en escenarios simulados. La aplicación registra valores manuales correctamente, los modelos ejecutan inferencias locales, y los datos se sincronizan exitosamente. Se evaluó la latencia y estabilidad entre condiciones variables de red, se elaboró en plan para integrar sensores Bluetooth Low Energy (BLE) como oxímetros y glucómetros, fase contemplada como desarrollo futuro para adquisición automática de datos biomédicos.

8. Herramientas de Desarrollo

Para la implementación de la aplicación móvil se utilizó Flutter, un marco de trabajo (framework) de interfaz de usuario de código abierto desarrollado por Google. Flutter permite la creación de aplicaciones compiladas de forma nativa para plataformas móviles (Android e iOS), web, escritorio (Windows, macOS y Linux) y sistemas embebidos, partiendo de una base de código única. El entorno emplea el lenguaje de programación Dart y proporciona un catálogo extenso de widgets, herramientas y bibliotecas prediseñadas que facilitan el desarrollo de aplicaciones de alto rendimiento. Una de las características fundamentales de este ecosistema es su capacidad multiplataforma potenciada por la funcionalidad Hot Reload; esta herramienta permite ciclos de prueba rápidos, agilizando la iteración de diseño y optimizando la experiencia del desarrollador (BrowserStack, 2025).

El modelo de inteligencia artificial que soporta la aplicación fue construido por TensorFlow 2.x y Keras, marcos reconocidos por su facilidad para el desarrollo y entrenamiento de redes neuronales artificiales. Una vez entrenados, los modelos se convirtieron al formato TensorFlow Lite (TFLite) para optimizar su ejecución en dispositivos móviles, lo que

permite inferencias rápidas y locales, manteniendo la privacidad de los datos del usuario (Google, 2025).

Para la gestión y sincronización de datos en tiempo real entre la aplicación móvil y la plataforma web se usó Firebase, una plataforma en la nube que proporciona autenticación segura, almacenamiento escalable y capacidades para actualizaciones instantáneas, esenciales para garantizar la comunicación eficiente y la seguridad entre pacientes y profesionales de la salud (Firebase, 2025 b).

El portal web para profesionales de la salud fue desarrollado con frameworks modernos como, React.js y Node.js, que permiten una interfaz dinámica, adaptable y una comunicación fluida con el backend para la gestión y visualización de registros clínicos, alertas y seguimiento de pacientes (Rootstack, 2025), como se muestra en la Figura 1, en la cual se tiene el registro de un Dr. cabe mencionar que los datos de la imagen son ficticios y se adjunta el nombre del médico, la especialidad médica, la universidad en la que estudio y la experiencia profesional que tiene. Posteriormente, se muestra un registro de sus pacientes. Este apartado es precisamente para el acompañamiento médico.



Figura 1. Interfaz de registro, Fuente: Creación propia.

Finalmente, Visual Studio Code (VSCode) se utilizó como editor de código fuente, complementado con GitHub para el control de versiones, colaboración del equipo de desarrollo y hospedaje del código fuente y modelos neurales, garantizando en flujo de trabajo organizado y seguro (Microsoft, 2025).

9. Resultados

En esta sección se presentan los hallazgos derivados del desarrollo, entrenamiento e implementación de las redes neuronales integradas en la aplicación móvil *NeuroMedX*, así como los resultados funcionales del sistema completo en escenarios de prueba. La primera red neuronal fue entrenada con un conjunto de datos conformados por síntomas y enfermedades comunes como se muestra en la Tabla 1, la relación de 4 enfermedades con 4 síntomas respectivamente, con el objetivo de establecer posibles relaciones entre los signos reportados por el usuario y las patologías más probables. Los datos fueron preprocesados mediante codificación categórica y normalización, garantizando que la red aprendiera patrones representativos. A continuación, se muestran algunos de las enfermedades y los síntomas asociados.

Enfermedad: Alergia estacional Síntomas: Estornudos, picazón nasal, ojos llorosos, congestión nasal
Enfermedad: Amigdalitis Síntomas: Dolor de garganta, fiebre, dificultad para tragar, ganglios inflamados
Enfermedad: Anemia por deficiencia de hierro Síntomas: cansancio, palidez, mareos, uñas frágiles
Enfermedad: Bronquitis Síntomas: Tos persistente, dificultad para respirar, fátiga, presión en el pecho

Tabla 1. Relación de enfermedad con síntomas, Fuente: (García Palomo et al., 2010).

Por otra parte, se adjunta la Tabla 2, que contiene la asociación de medicamentos relacionado a la enfermedad que asocia la red neuronal

Nombre: Aciclovir Descripción: Antiviral Usos: Herpes simple y zóster Reacciones: Náuseas, mareos, diarrea Presentación: Tabletas de 400-800 mg Contraindicaciones: Insuficiencia renal severa Dosis: 400 mg cada 8 horas Tipo: Antiviral
Nombre: Amiodarona Descripción: Antiarrítmico potente Usos: Arritmias ventriculares y supraventriculares Reacciones: Fotosensibilidad, temblores Presentación: Tabletas de 200 mg Contraindicaciones: Bradicardia severa Dosis: Tipo: Antiarrítmico

Tabla 2. Relación de medicamentos con enfermedades, Fuente: (García Palomo et al., 2010).

9.1 Desempeño de la red neuronal/ Enfermedades.

El modelo principal basado en un perceptron multicapa (MLP) para análisis y predicción de enfermedades alcanzó una precisión final del 91%. Durante el entrenamiento realizado con 400 épocas, se logró una pérdida (loss) de 0.1557 y una alta exactitud en la clasificación de 14 enfermedades distintas, utilizando 43 síntomas normalizados y procesados. Esta arquitectura incluyó dos capas ocultas como Dense con activación ReLU y dropout para evitar sobreajuste, finalizando en una capa Softmax para salida probabilística.

La segunda red neuronal, fue entrenada con información relacionada con nombres, clasificaciones y propiedades farmacológicas de medicamentos, así como sus indicaciones y contraindicaciones generales. El propósito de esta red es asistir en la identificación contextual de medicamentos, ofreciendo información útil y confiable para el usuario, sin sustituir la valoración médica. A continuación, en la Figura 2, se muestra una consulta de medicamentos en la aplicación *NeuroMedX*.

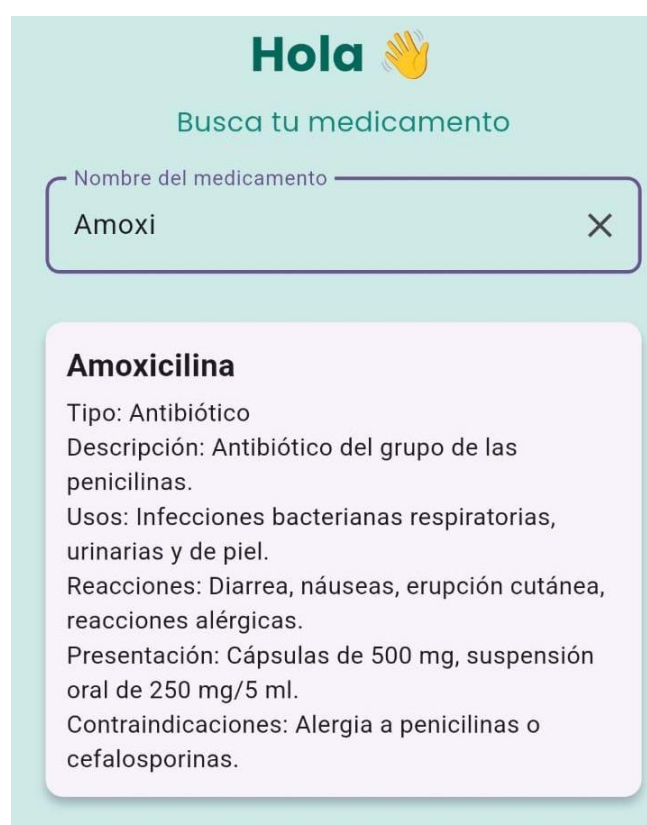


Figura 2. Interfaz búsqueda de medicamento, Fuente: Creación propia.

9.2 Desempeño de la red neuronal/ Enfermedades.

Para la identificación automática de medicamentos, se desarrolló un modelo de red neuronal multicapa (Multi-Layer Perceptron, MLP) que procesa presentaciones de tokenización de nombres de medicamentos. Este modelo clasifica 23 medicamentos diferentes, procesando un vocabulario de 39 tokens, mediante una arquitectura compuesta por capas densas intercaladas con capas de dropout para evitar sobreajuste.

El entrenamiento se realizó durante 400 épocas, con la función de pérdida final de 0.249 y una precisión global del 89.86%. El modelo cuenta con 8,215 parámetros entrenables y fue evaluado con un conjunto de prueba tokenizado, generando

una matriz de confusión que refleja una clasificación mayoritariamente correcta de los medicamentos, aunque con ligeras confusiones en clases cuyos nombres comparten tokens similares. Los medicamentos reconocidos incluyen Aciclovir, Amiodarona, Amoxicilina, Azitromicina, Cetirizina, entre otros. Este desempeño demuestra la eficiencia del modelo para la automatización de consultas farmacológicas dentro del entorno de la aplicación móvil. Estos resultados evidencian que la combinación de capas densas y dropout permite un entrenamiento estable y un desempeño robusto en la clasificación automática de medicamentos. Se proyectan futuras mejoras mediante la expansión de vocabulario de tokens y la incorporación de técnicas avanzadas de embedding para mejorar la discriminación entre medicinas con nombre similares.

9.3 Integración y funcionamiento de la App móvil.

Una vez entrenadas y optimizadas las redes neuronales, se procedió a su integración mediante el paquete tflite_flutter en Flutter para la carga e inferencia de los modelos. La aplicación fue configurada para ejecutar las dos redes neuronales de manera local, de modo que los resultados de cada inferencia ya sea la identificación de posibles enfermedades o la descripción de un medicamento, se procesan directamente en el dispositivo, garantizando mayor privacidad y menor dependencia de conexión. El backend basado en Firebase permitió la sincronización segura y en tiempo real de datos biomédicos, facilitando el seguimiento remoto y la actualización constante del historial clínico en la plataforma web.

9.4 Pruebas funcionales y experiencia de usuario.

Se realizaron pruebas en escenarios simulados verificando la robustez del sistema: ingresos manuales de signos vitales, respuestas del modelo neuronal, sincronización de registros y recepción de alerta automáticas en el portal web. La latencia y la estabilidad mostraron niveles adecuados para uso cotidiano. Se planea la incorporación futura de sensores Bluetooth Low Energy (BLE) para permitir la adquisición y continua de datos biométricos, lo que ampliará significativamente la capacidad predictiva y la usabilidad del sistema.

9.5 Visualización y análisis de datos.

Se generaron curvas de aprendizaje que muestran la evolución estable de precisión y pérdida durante el entrenamiento del modelo, junto con una matriz de confusión de los síntomas que se muestra en la Tabla 3, donde se clasifican las 14 enfermedades, que evidencian la capacidad del sistema para diferenciar efectivamente las enfermedades estudiadas. Además, se capturaron ejemplos de inferencias realizadas en la aplicación, que validan la coherencia y relevancia clínica de las predicciones. Estos resultados evidencian que la combinación de capas densas y dropout permite un entrenamiento estable y un desempeño robusto en la clasificación automática de medicamentos. Se proyectan futuras mejoras mediante la expansión de vocabulario de tokens y la incorporación de técnicas avanzadas de embedding para mejorar la discriminación entre medicinas con nombre similares.

10. Discusión

Los resultados obtenidos mediante las arquitecturas neuronales implementadas en NeuroMedX demuestran la viabilidad técnica y clínica de un sistema inteligente para la gestión de la salud en dispositivos móviles. El modelo de Perceptrón Multicapa (MLP) para la predicción de enfermedades alcanzó una precisión del 91%, mientras que la red convolucional destinada a la identificación de fármacos obtuvo un 90%. Estos valores de desempeño son consistentes con el estado del arte en aprendizaje profundo aplicado al diagnóstico médico, reforzando la pertinencia de la IA en la salud digital. Asimismo, la arquitectura permite el

MATRIZ DE CONFUSIÓN													
13	0	0	0	0	0	0	0	14	24	13	13	5	14
0	14	0	0	0	1	12	0	1	0	1	1	0	0
0	0	12	0	0	0	0	0	14	0	0	0	0	0
0	0	0	14	0	0	0	0	0	0	0	0	0	0
0	0	0	0	24	0	0	0	0	0	0	0	0	0
0	0	0	0	0	7	0	0	0	1	0	0	0	0
0	0	0	0	0	0	12	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	14	0	0	0	0	0
0	0	0	0	0	6	1	0	24	0	0	0	0	0
0	0	0	0	0	0	1	0	0	13	0	0	0	0
0	0	0	0	0	0	0	0	0	0	13	0	0	0
0	0	0	0	0	0	0	0	0	0	0	5	0	0
1	0	0	0	0	0	0	0	0	0	0	0	0	14
0	0	0	0	0	0	0	0	0	0	0	0	1	0

Figura 3: Matriz de confusión Fuente: Creación propia.

La matriz presentada resume el desempeño de un modelo de clasificación multiclase. Cada fila representa las instancias reales de una clase, mientras que cada columna indica las predicciones realizadas por el modelo.

- Los valores en la diagonal principal (como 13, 14, 7 etc.) muestran los casos correctamente clasificados, es decir, cuando la clase coinciden con la predicha
- Los valores fuera de la diagonal principal reflejan los errores de clasificación, indicando hacia qué clase se confundieron las instancias. Por ejemplo, en la primera fila se observa que, además de 13 aciertos, hubo confusiones con otras clases (14, 24, 5, etc.)
- Esto permite identificar patrones de error: algunas clases son reconocidas con alta precisión, (fila 4, 5, 7, 8,9, donde casi todos los valores están en diagonal), mientras que otras muestran mayor dispersión y confusión con categorías vecinas

procesamiento local (Edge Computing), lo que garantiza la privacidad del usuario y la continuidad operativa sin dependencia constante de la nube.

No obstante, es imperativo señalar que en las fases iniciales de inferencia local se identificó una tasa de error semántico del 60%. Esta discrepancia inicial se superó mediante la optimización del proceso de tokenización y el refinamiento de las capas de embedding, logrando que el modelo capturara con mayor precisión las relaciones latentes en los datos médicos. Para futuras iteraciones, la ampliación del vocabulario técnico y la diversificación de los conjuntos de datos supervisados de entrenamiento serán cruciales para mantener la robustez del sistema en entornos no controlados. En conclusión, NeuroMedX ofrece una alternativa escalable y accesible que mitiga la fragmentación de los servicios de salud, siendo especialmente relevante en regiones con infraestructura de conectividad limitada.

11. Conclusiones y mejoras futuras

Este proyecto supone un progreso relevante en la creación de soluciones móviles que incorporan inteligencia artificial para la telemedicina y el seguimiento preventivo. NeuroMedX no solo mejora el seguimiento médico al hacerlo más accesible y personalizado, sino que además promueve la comunicación entre el paciente y el profesional. Como una línea futura, se ha proyectado incluir un chatbot inteligente con el fin de optimizar la interacción entre usuario y sistema además de simplificar las consultas automatizadas. También se contempla integrar sensores Bluetooth Low Energy (BLE) para que se posibiliten la recolección automatizada de datos biométricos en tiempo real,

Estas optimizaciones aumentarán la capacidad de uso, exactitud y funcionalidad, fortaleciendo el sistema como una herramienta integral para brindar atención médica a distancia.

12. Referencias

- Alom, M. Z. (2025). An explainable {AI}-based deep neural network for accurate breast cancer detection from histopathological and ultrasound images. *Scientific Reports*, 15(1), 5-35. doi:10.1038/s41598-025-12345-x
- American Medical Association. (2025, Octubre 21). Retrieved from AMA: <https://www.ama-assn.org/practice-management/digital-health/augmented-intelligence-medicine>
- Aracena, R. (2022). Inteligencia artificial en salud: Oportunidades y desafíos para la medicina actual. *Revista Médica Clínica Las Condes*, 33(5), 450–458. doi:10.1016/j.rmcl.2022.08.001
- Association, A. M. (2025, Octubre 21). *Augmented intelligence in medicine*. Retrieved from AMA: <https://www.ama-assn.org/practice-management/digital-health/augmented-intelligence-medicine>
- BrowserStack. (2025, Marzo 4). *Understanding Flutter's Hot Reload: Enhancing Developer Experience in Cross-Platform Development*. Retrieved from <https://www.browserstack.com/guide/flutter-hot-reload>
- BrowserStack. (2025, Marzo 4). *What is Flutter*. Retrieved from BrowserStack: <https://www.browserstack.com/guide/what-is-flutter>
- Cortes, V. (2020). *Digital health platforms for patient care*. Retrieved from Chetu: <https://www.chetu.com/es/blogs/healthcare/digital-health-platforms-for-patient-care.php>
- DiriCloud. (2025). *Plataforma médica digital para la gestión y monitoreo de la salud*. Retrieved from DiriCloud: <https://dricloud.com/plataforma-medica/>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2021). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, pp. 115–118. doi:10.1038/nature21056
- Firestore. (2025 a, noviembre 06). *Firestore platform overview*. Retrieved from Firestore: <https://firebase.google.com/?hl=es-419>
- Firestore. (2025 b, octubre). *Firestore platform overview*. Retrieved from Firestore: <https://firebase.google.com/>
- Flutter. (2024). *Google*. Retrieved from Flutter: Build apps for any screen: <https://flutter.dev/>
- Google. (2025). *LiteRT: AI for edge devices*. Retrieved from Google AI: <https://ai.google.dev/edge/litert>
- Jalife, M. (2024, abril 29). *Ética y regulación de la inteligencia artificial en la medicina contemporánea*. Ciudad de México, México: Editorial Médica Panamericana. Retrieved from Centro medico digital: <https://centromexico.digital/inteligencia-artificial-en-la-salud-riesgos-y-ventajas/>
- Lane, N. (2015). Can deep learning revolutionize mobile sensing. *Proceedings of the 16th International Workshop on Mobile Computing Systems and Applications (HotMobile '15)*, 117-122.
- Mayer-Schönberger, V., & Cukier, K. (2013, Enero). *Big Data: A Revolution That Will Transform How We Live, Work, and Think*. Boston, MA, Estados Unidos: Houghton Mifflin Harcourt. doi:978-0544002692
- Microsoft. (2025). *Visual Studio Code Documentation*. Retrieved from Microsoft: <https://code.visualstudio.com/docs>
- Organización Panamericana de la Salud. (2022). *Sistemas de información para la salud*. (OPS/OMS, Editor) Retrieved from Organización Panamericana de la salud: <https://www.paho.org/es/temas/sistemas-informacion-para-salud>
- Organization, W. H. (2021, agosto 18). *Global strategy on digital health 2020–2025*. Retrieved from World Health Organization: <https://www.who.int/publications/i/item/9789240020924>
- Rootstack. (2025). *Node.js vs React: crear sitio web*. (Rootstack, Editor) Retrieved from Rootstack: <https://rootstack.com/es/blog/nodejs-vs-react-crear-sitio-web>
- SaludByDiaz. (2025, Marzo 7). *Monitorización y diagnóstico de la salud mediante métodos de deep learning*. Retrieved from Gestion y economia de la salud: <https://saludbydiaz.com/2025/03/07/monitorizacion-y-diagnostico-de-la-salud-mediante-metodos-de-deep-learning/>
- Shaik, T. (2023, enero 5). Retrieved from Wires : https://wires-onlinelibrary-wiley-com.translate.goog/doi/10.1002/widm.1485?cookieSet=1&_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc
- TensorFlow. (2024). *Model optimization toolkit*. Retrieved from TensorFlow: https://www.tensorflow.org/model_optimization?hl=es
- Topol, E. J. (2021, Enero 7). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, pp. 1-5.
- World Health Organization. (2021, Agosto 18). *Global strategy on digital health 2020–2025*. World Health Organization, Ginebra, Suiza. doi:978-92-4-002092-4

Agradecimientos

Los autores expresan su agradecimiento a Tecnológico de Estudios Superiores de Tianguistenco.