

Detección temprana de la enfermedad de Parkinson mediante técnicas de aprendizaje profundo

Jaime Hernández-Ramírez¹, Giner Alor-Hernández¹,
Nancy Aracely Cruz-Ramos¹, José Luis Sánchez-Cervantes²,
Lisbeth Rodríguez-Mazahua¹

¹ Tecnológico Nacional de México,
Instituto Tecnológico de Orizaba,
México

² Consejo Nacional de Ciencia y Tecnología,
Tecnológico Nacional de México,
Instituto Tecnológico de Orizaba,
México

dci.ncruz@ito-depi.edu.mx, {M21011175, giner.ah,
jose.sc, lisbeth.rm }@orizaba.tecnm.mx

Resumen. La enfermedad de Parkinson (EP) es un trastorno neurodegenerativo progresivo que afecta a más de 10 millones de personas en todo el mundo, representando una importante disminución de la calidad de vida del paciente y sus familiares. Es por ello que, el diagnóstico temprano representa un papel fundamental en el tratamiento de los síntomas. Sin embargo, a pesar de los esfuerzos realizados para la recolección de información clínica, muchos de los métodos no proporcionan la precisión y sensibilidad suficiente para la detección temprana de la EP. En este trabajo, se desarrolló un módulo web para la detección temprana de la EP mediante ejercicios de trazabilidad utilizando técnicas de Aprendizaje Profundo. Los resultados presentan estadísticas favorables en precisión y eficacia, destacando los valores obtenidos por el algoritmo Random Forest. Además, este enfoque se muestra como herramienta de gran potencial en el apoyo al sector médico en la toma de decisiones para mejorar la calidad de vida del paciente.

Palabras clave: Aprendizaje profundo, enfermedades neurodegenerativas, inteligencia artificial, Parkinson.

Early Detection of Parkinson's Disease Using Deep Learning Techniques

Abstract. Parkinson's disease (PD) is a progressive neurodegenerative disorder that affects over 10 million people worldwide, representing a significant decrease in the patient's quality of life and their families. Therefore, early diagnosis plays a crucial role in symptom treatment. However, despite efforts made for clinical information collection, many methods do not provide sufficient accuracy and sensitivity for early detection of PD. In this work, a web module for early

detection of PD using traceability exercises and Deep Learning techniques was developed. The results present favorable statistics in accuracy and efficacy, highlighting the values obtained by the Random Forest algorithm. Furthermore, this approach shows great potential as a tool to support the medical sector in decision-making to improve the patient's quality of life.

Keywords: Deep learning, neurodegenerative diseases, artificial intelligence, Parkinson's disease.

1. Introducción

La enfermedad de Parkinson (EP) es un trastorno neurodegenerativo progresivo que, de acuerdo con Dorsery et al. [1], afecta a más de 6 millones de personas en todo el mundo y se prevé que esta cifra para el año 2040, sea duplicada, donde además, la mayoría de personas que cuentan con este padecimiento no obtiene un diagnóstico positivo, sino hasta una edad posterior a los 50 años.

Por su parte, el Instituto Nacional de Neurología y Neurocirugía [2], considera la confirmación de 150 a 200 casos por cada 100,000 habitantes al año en diversas partes del mundo, donde tan solo en México 50 de cada 100,000 habitantes son posibles candidatos de este padecimiento.

La EP se caracteriza por ser una enfermedad que influye directamente al sistema nervioso del paciente que lo padece, esto se debe, a la muerte de células nerviosas en el cerebro encargadas de la producción de dopamina, un neurotransmisor clave en el control del movimiento y la coordinación muscular.

Algunos de los síntomas presentados en una edad temprana incluyen, temblor, rigidez, dificultar para caminar, hablar y problemas de equilibrio, resultando con el tiempo, la disminución de la calidad de vida de los pacientes y sus familiares.

A pesar de que no existe cura para la EP, el diagnóstico temprano, es fundamental para el tratamiento y monitoreo de los síntomas, es así que, se cuenta con investigaciones que dedican esfuerzos en el análisis y recolección de información clínica con el fin de brindar herramientas de apoyo al personal médico y pacientes en la detección y seguimiento de la EP, aunque, actualmente los diagnósticos basan sus resultados en la observación clínica y la evaluación de síntomas, la mayoría de estos métodos no proveen la precisión y sensibilidad suficiente para detectar la enfermedad en sus primeras etapas, delimitando tratamiento adecuado del paciente donde la enfermedad ya cuenta con un amplio desarrollo.

Por otro lado, la Inteligencia Artificial (IA) ha demostrado, en los últimos años, ser una herramienta de gran relevancia en el sector de la salud, protagonizando, entre diversos proyectos, la detección temprana, seguimiento y toma de decisiones sobre diversas enfermedades, tales como, el Parkinson, Alzheimer, el cáncer y SARS-CoV-2 (COVID-19).

Se han desarrollado propuestas que también cuentan con el impulso de técnicas de Aprendizaje Profundo (AP), rama de la IA que tiene como principal participante, prometedores modelos en sistemas de clasificación de resultados, destacando en detección temprana de la EP por sus estudios.

En este trabajo se desarrolló un módulo web para la detección temprana de la EP mediante ejercicios de trazabilidad utilizando técnicas de AP, brindando así, una

herramienta de diagnóstico temprano que busca brindar apoyo en la toma de decisiones por parte del sector médico, mejorando así, la calidad de vida del paciente.

Este trabajo presenta la siguiente estructura, la sección 2 aborda los trabajos de literatura relacionados con la detección de la EP mediante técnicas de AP. La sección 3 presenta la arquitectura del módulo propuesto durante la investigación realizada. La sección 4 presenta un caso de estudio como prueba de concepto. Finalmente, en la sección 5 se presentan las conclusiones alcanzadas durante el desarrollo de la investigación.

2. Trabajos relacionados

En esta sección, se presentan diversas investigaciones de proyectos relacionados con la detección temprana de la EP mediante AP, enfocadas en diferentes herramientas, técnicas y pruebas de diagnóstico. Como grupo principal, se presentan a continuación investigaciones que propusieron herramientas digitales para el diagnóstico y seguimiento de pacientes con la EP.

Worasawate et al. [3], analizaron los datos de grabación de voz de un teléfono inteligente como posible herramienta de autodiagnóstico médico, los resultados demostraron precisiones de clasificación con valores estimados del 97% al 99%. Similarmente, Punarselvam et al. [4] propusieron un sistema de monitorización de la señal de la voz mediante elementos de Internet de las Cosas (IoT), los resultados demostraron métricas de precisión, sensibilidad y especificidad por encima del 95%.

Por su parte, Fraiwan et al. [5] presentaron un sistema de detección del movimiento rítmico involuntario mediante una aplicación móvil enlazada con los sensores incorporados, los resultados del estudio demostraron valores de precisión de hasta 95%. De manera similar, Zhang et al. [6] enfocaron su estudio en el desarrollo de DeepVoice, una aplicación de recolección de la huella de voz en dominio del espectrograma fonético, la precisión promedio obtenida por el modelo fue de 90.45%.

Considerando la introducción de herramientas digitales, Kuosmanen et al. [7] desarrollaron STOP, una aplicación de seguimiento de síntomas y gestión de la ingesta médica, donde los resultados demostraron una aceptación positiva al uso de herramientas para el tratamiento de la EP.

Similarmente, ocurrió con los trabajos de Hu et al. [8], Martin et al. [9] y Linares-del Rey et al. [10], donde el enfoque se dirigió con respecto a la inspección sistemática sobre el uso de herramientas digitales para la gestión, seguimiento y ejecución de tareas relacionadas al estudio de la EP, dando como resultado común, factores de aceptación positivos por parte de los pacientes y personal médico.

En segunda instancia, se analizaron estudios de proyectos enfocados en la detección de la EP mediante la aplicación de ejercicios de trazabilidad y supervisión de la actividad motriz, pruebas dedicadas en evaluar el rendimiento continuo de los pacientes a través de los resultados obtenidos, estas investigaciones se mencionan a continuación. Kotsavasiloglou et al. [11] estudiaron el uso de dispositivos digitalizadores para analizar las diferencias entre el movimiento y coordinación manuscrita.

Como resultado demostraron una precisión de análisis de 91% mediante clasificadores de redes bayesianas. Camps et al. [12] proponen un método de análisis por congelación de la marcha mediante monitoreo espectral de la inercia, proceso

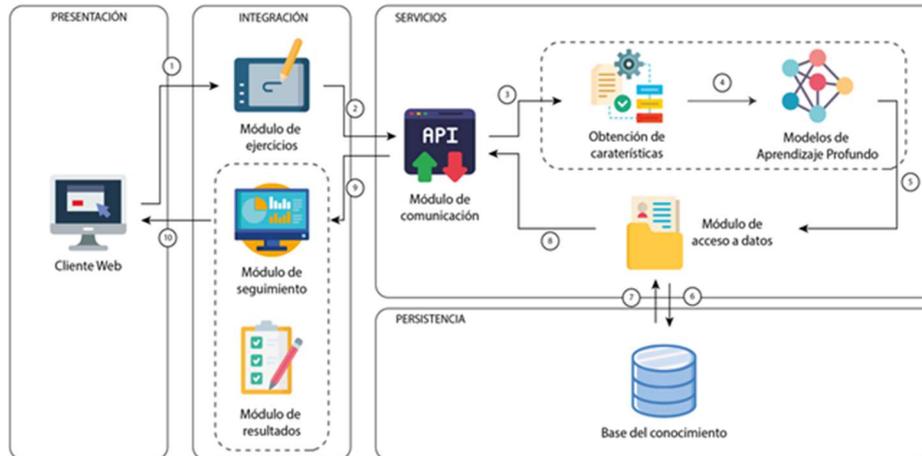


Fig. 1. Arquitectura del módulo web para la detección temprana de la EP.

impulsado por el algoritmo Support Vector Machine (SVM) con resultados de precisión de 87%.

Alkhatib et al. [13] desarrollaron un algoritmo de alto nivel enfocado en segmentar grupos de estudio en función de la distribución de carga durante la marcha, los resultados presentaron valores de precisión en un 95%.

Desde otra perspectiva, Rovini et al. [14] implementaron la recopilación de estadísticas de la actividad motriz utilizando dispositivos de seguimiento portátiles, como resultado observaron mejor precisión (95%) al implementar RF como principal algoritmo de clasificación.

Así mismo, Moshkova et al. [15] implementaron técnicas de AP para la clasificación de datos obtenidos mediante sensores Leap Motion, los clasificadores analizados destacaron a Random Forest (RF) en 90.6% como la precisión de mayor rango.

Por otro lado, investigaciones también reconocen la detección de la EP mediante el diagnóstico de diversas pruebas, tales como, el análisis de temblores en el estado de reposo, muestras de estudio del lenguaje natural y seguimiento en la afección causada en neuronas dopaminérgicas, estos estudios se presentan a continuación.

Yao et al. [16] presentaron un enfoque de estudio mediante el análisis de temblores en el estado de reposo, durante la comparación de resultados, los algoritmos RF y XGBoost obtuvieron el mejor resultado de precisión (>70%). Anand et al. [17] diagnosticaron la probabilidad de padecimiento mediante el estudio de lenguaje natural, los clasificadores representados en el modelo de AP destacaron a los algoritmos KNN y RF con mejores métricas de rendimiento.

Con enfoque distinto, Wodzinski et al. [18] realizaron el estudio de espectrogramas vocales mediante una arquitectura ResNet, donde el modelo propuesto expuso valores de precisión de 91% en el uso de algoritmos como RF y SVM.

Mientras que, Prashanth et al. [19] dirigieron la investigación al estudio de la pérdida de neuronas dopaminérgicas, durante el seguimiento las estadísticas resultantes, se demostró que el algoritmo SVM contó con el mayor grado de precisión obtenido.

Tabla 1. Resultados comparativos de los algoritmos de clasificación.

#	Algoritmo	Precisión	Sensibilidad	Especificidad	F1 Score
1	KNN	0.808	0.913	0.783	0.857
2	Decision Tree	0.679	0.826	0.609	0.745
3	SVM	0.792	0.826	0.783	0.809
4	GB	0.818	0.783	0.826	0.800
5	LightGBM	0.792	0.826	0.783	0.809
6	XGBoost	0.760	0.826	0.739	0.792
7	RF	0.909	0.870	0.913	0.889
8	CatBoost	0.739	0.739	0.739	0.739
9	AdaBoost	0.739	0.739	0.739	0.739

A su vez, con el enfoque determinante en la generación de estadísticas y desarrollo de nuevos modelos, se exploraron investigaciones que ofrecieron como resultados, valores de rendimiento obtenidos en la comparación de diversas técnicas y procesos de análisis, observando lo siguiente.

Arora et al. [20] realizaron pruebas de clasificación con base en registros de pacientes mediante su expediente clínico estandarizado, como resultado, RF presentó óptimas métricas de rendimiento con resultados de sensibilidad en 96.2% y 96.9%. Por su parte, Ali et al. [21] propusieron el desarrollo de un sistema de aprendizaje escalonado, demostrando una mejora de rendimiento frente al uso de clasificadores independientes, este conjunto destacó AdaBoost con un incremento de mejora en 3.3%.

De manera similar, Karapinar et al. [22] propusieron diagnosticar el rendimiento obtenido por distintos algoritmos de clasificación en la detección de la EP, la tabla de resultados demostró SVM con el mejor desempeño obtenido en valores de precisión. Del mismo modo, Haq et al. [23] durante su investigación, compararon las distintas ventajas del rendimiento que ofrecen diversas metodologías de AP en el campo de la EP, resultados destacaron a SVM como una de las principales alternativas.

De manera semejante, Pahuja et al. [24] decidieron realizar la comparación de diversas tecnologías para la detección de la EP, incorporando entre los algoritmos de mejor rendimiento en valor de precisión hallado, Levenberg-Marquardt y SVM.

Adicionalmente, La investigación Nilashi et al. [25] propuso el desarrollo de un modelo híbrido para la detección de la EP mediante múltiples algoritmos de clasificación, los resultados permitieron reconocer las ventajas tanto individuales como globales de cada uno, así como también el alto impacto obtenido al incorporar herramientas de AP en el campo de la detección de la EP.

3. Arquitectura del módulo para la detección temprana de la enfermedad de Parkinson

En este trabajo, se desarrolló un módulo web enfocado en el proceso de identificación de la EP mediante el uso de ejercicios de trazabilidad y un clasificador impulsado por una red neuronal convolucional (CNN). Este módulo tiene como función brindar una conexión entre la plataforma y el modelo de clasificación entrenado en indicar el valor probabilidad de padecimiento, de acuerdo con determinadas reglas de

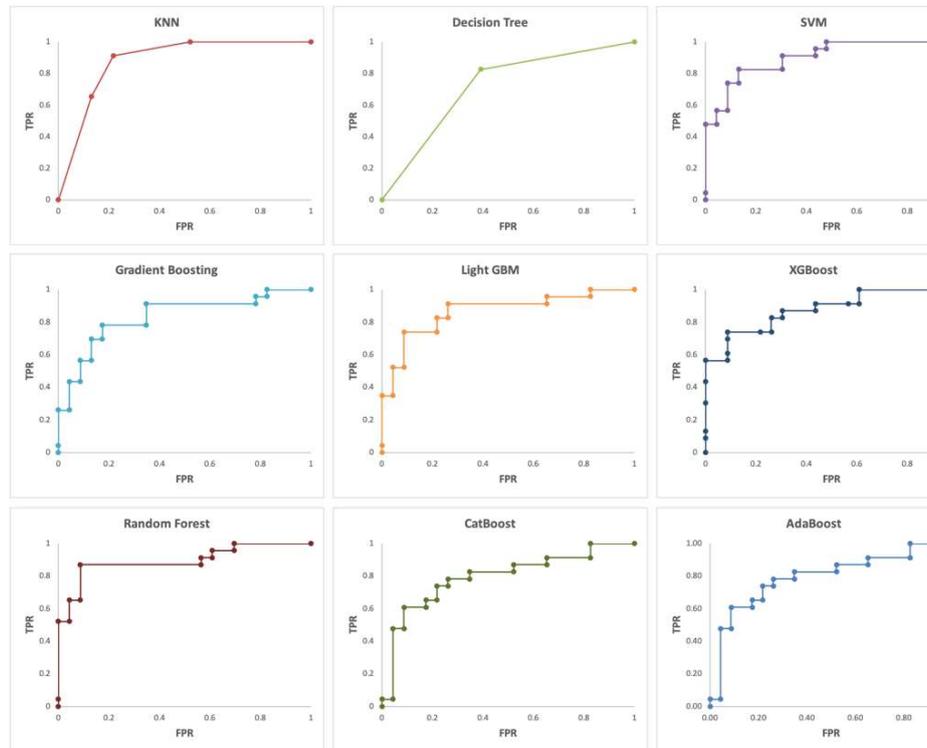


Fig. 1. Resultados de la curva ROC.

referencia. El esquema global del módulo, comienza con la plataforma web, la cual es el punto de partida dedicado al personal médico y con el objetivo de realizar pruebas de detección mediante ejercicios de trazabilidad con el paciente.

Esta plataforma cuenta con diversas secciones operativas, entre las cuales, se considera, la aplicación de nuevos estudios y revisión de la evolución del paciente, enfocado en el historial de pruebas realizadas. Durante la aplicación de nuevos estudios el módulo recopila, procesa, interpreta y recupera los resultados obtenidos para su posterior seguimiento y monitorización.

La obtención de datos es un proceso guiado mediante una tableta digitalizadora que permite al paciente ilustrar un conjunto de ejercicios de trazos con base en plantillas predefinidas. Los datos obtenidos mediante la tableta se determinan con base en las propiedades del trazo realizado, tales como la precisión, la presión, rapidéz e inclinación ejecutada por el usuario durante el seguimiento del ejercicio.

Posteriormente el resultado se convierte en un conjunto de ilustraciones y propiedades cuyo objetivo es ser enviados a un servidor externo, donde el clasificador se enfoca en el procesamiento e interpretación de datos, finalmente, los valores obtenidos se registran para seguimiento y consulta médica.

El módulo está distribuido en un modelo arquitectónico basado en capas para brindar una solución de mejor escalabilidad, robustez y de fácil mantenimiento. Durante el proceso de desarrollo se consideró el uso de diversas tecnologías, con motivo de

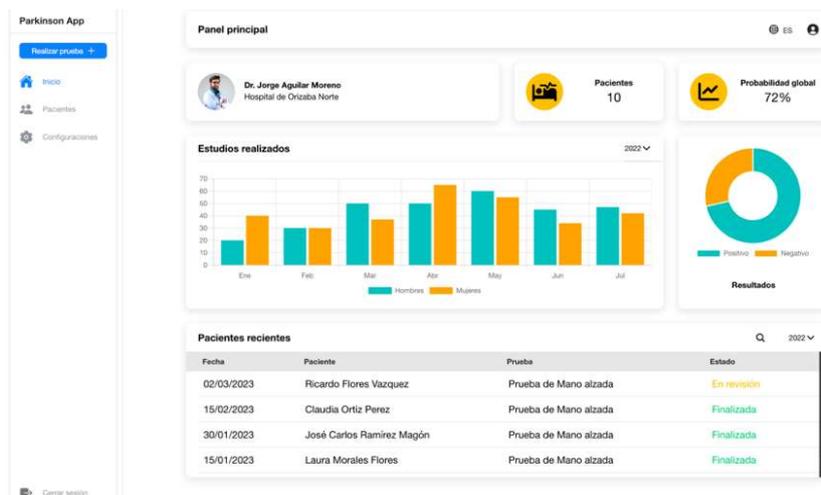


Fig. 2. Módulo web - panel principal.

garantizar un mejor rendimiento entre los procesos involucrados, así como también medidas de seguridad para garantizar la integridad de los datos.

La arquitectura del módulo desarrollado se describe en la Fig. 1, donde además se encuentra señalado a través de etiquetas enumeradas (1-10) el flujo de trabajo principal “Clasificación de una prueba de trazabilidad”. A continuación, se describe cada una de las capas integradas en la arquitectura.

- **Capa de presentación:** es la aplicación web principal, encargada de proporcionar al usuario una interfaz gráfica para la recopilación y seguimiento de las pruebas, esta capa está diseñada de manera óptima en concepto de usabilidad, con el objetivo de brindar una mejor experiencia de usuario por el personal médico y su interacción con el paciente.
- **Capa de integración:** está compuesta por diferentes módulos encargados de realizar funciones específicas dentro del sistema. El módulo de ejercicios tiene por motivo, obtener los ejercicios realizados por el paciente mediante una tableta digitalizadora. El módulo de seguimiento incorpora un conjunto de estadísticos referentes al historial de resultados globales de cada paciente. El módulo de resultados tiene como objetivo presentar al médico los resultados obtenidos por el clasificador de forma clara y concisa. Finalmente, todos los datos interpretados por esta capa se envían a la capa de servicios mediante su interfaz de acceso, módulo de comunicación.
- **Capa de servicios:** compuesta también por distintos módulos determina los casos de uso de predicción de estudios y consulta de datos. Referente al proceso de predicción se establecieron los módulos de obtención de características, enfocado en la lectura y análisis de instancias gráficas; y modelos de AP, encargados de la interpretación de instancias y clasificación de resultados mediante los algoritmos previamente entrenados para su uso. El módulo de acceso a datos proporciona una interfaz de acceso a la capa de persistencia para almacenar los datos obtenidos. Finalmente, el módulo de comunicación se integra como único punto de entrada y salida, encargado de la comunicación con la capa de integración.

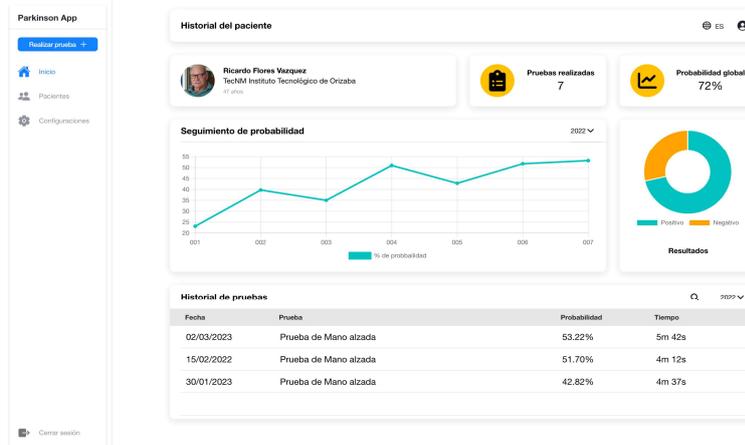


Fig. 3. Módulo web - Panel expediente del paciente.

- **Capa de persistencia:** incorpora la base de datos principal del módulo, encargada de almacenar la información necesaria para su posterior análisis y seguimiento.

4. Caso de estudio: Identificación temprana de síntomas de la enfermedad de Parkinson

En esta sección se describe el caso de estudio desarrollado para la identificación temprana de síntomas de la EP mediante ejercicios de trazabilidad y técnicas de AP.

4.1. Características de la aplicación

Como punto de partida en selección de tecnologías para el desarrollo de la aplicación web, se implementó el marco de trabajo de IONIC impulsado por la tecnología Angular, el cual proporciona amplia facilidad de uso y soporte, lo que permite una integración rápida y eficiente en el desarrollo de interfaces gráficas para el usuario, así como también, el despliegue híbrido para nuevas áreas de oportunidad como el uso de plataformas móviles [26, 27].

Así también, se utilizó Flask de Python que es un micro marco de trabajo debido a su sencillez y flexibilidad, así como también destaca sus capacidades de integración con nuevas tecnologías, es por ello que, se determinó como herramienta ideal para la construcción del núcleo de la aplicación [28].

A su vez, para el módulo de inteligencia, encargado de la distribución de los algoritmos de clasificación, se seleccionó Scikit-Learn que es una biblioteca de AP con base de código en el lenguaje Python que proporciona herramientas simples y eficientes para la minería y análisis de datos [29]. Mediante esta biblioteca, se realizó la integración de diversos algoritmos, así como también, su comparación de métricas de rendimiento para la selección óptima en caso de estudio.

Finalmente, como base de conocimiento, se determinó MySQL para el almacenamiento de datos y control de registros, herramienta seleccionada debido a su

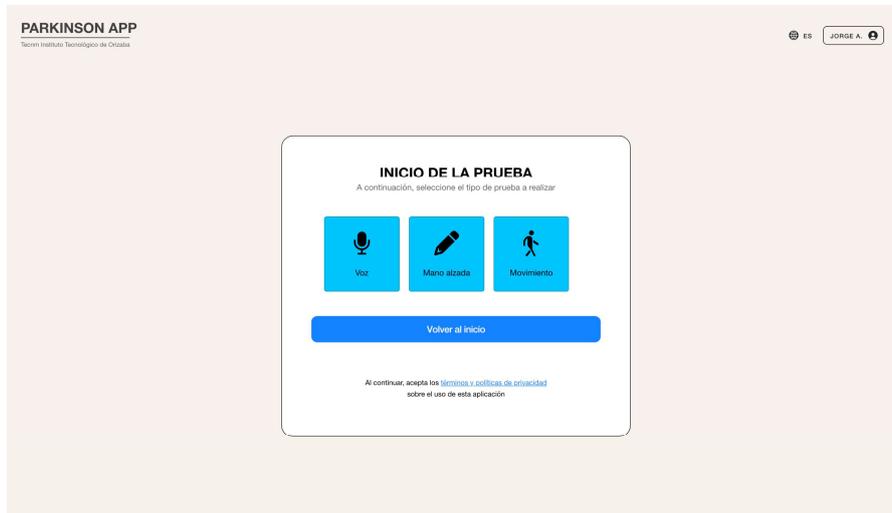


Fig. 4. Módulo web - Catálogo de pruebas.

optimización de recursos, amplio soporte y fácil integración con las herramientas de infraestructura del servidor, facilitando así, la correcta gestión de la información.

4.2. Selección de algoritmos de clasificación

Como parte fundamental del proyecto, se realizó la investigación comparativa de nueve algoritmos de clasificación de AP, mismos que se encontraron con mejores resultados dentro de la literatura, cada uno de los algoritmos se puso a prueba bajo un entorno preparado a través de un mismo conjunto de datos y métricas de estudio.

Como resultados obtenidos durante la comparación, se demostró que el clasificador RF obtuvo los valores óptimos en términos de precisión y especificidad, obteniendo así un puntaje promedio de 90.9% y 91.3% respectivamente en las pruebas de detección, como segundo clasificado, se observó a Gradient Boosting (GB) con una puntuación de precisión en 81.8% y especificidad de 82.6%. En la Tabla se observa a detalle los valores obtenidos por los clasificadores durante su análisis.

Se observa que los resultados obtenidos en esta comparación muestran que, durante la determinación de los clasificadores, RF representó los mejores puntajes de rendimiento, determinando así, el principal modelo a implementar, seguido por el algoritmo GB en términos de precisión.

Además, se llevaron a cabo pruebas comparativas entre los clasificadores mediante el estudio de la curva ROC, la cual representa la relación entre la sensibilidad y especificidad de cada modelo.

Los resultados de estas pruebas permitieron confirmar los resultados anteriores, a continuación, en la Fig. 1 se muestran los resultados obtenidos durante su análisis.

Como se observa, durante el análisis RF continúa representando un mejor balance en el resultado obtenido, seguido en este caso por el algoritmo SVM, y en tercera posición GB, dejando de lado entre demás opciones, el algoritmo KNN, que, si bien



Fig. 5. Módulo web - Aplicación de la prueba.

mantiene valores óptimos de precisión y sensibilidad, no proporciona el mejor balance en el análisis de la curva ROC, y por ello, no se consideró para su implementación.

Como resultado concluyente, la comparación se realizó mediante cinco métricas y nueve algoritmos de clasificación distintos, donde se obtuvo las opciones de RF, GB y SVM, como los principales clasificadores a implementar en el módulo de detección temprana de la EP mediante técnicas de AP.

4.3. Proceso de detección

En este apartado se presenta el proceso de detección a través del módulo desarrollado, el escenario a considerar fue mediante un paciente masculino de 60 años que presenta un diagnóstico positivo de la EP.

Para ello, con asistencia médica el paciente utilizó el módulo web realizando pruebas de trazabilidad para posteriormente enviarlas al clasificador de AP, y finalmente, obtener resultados que permitieron al personal médico evaluar de forma objetiva la condición del paciente. Para el proceso de detección, el módulo cuenta con varias interfaces y pasos que permiten una aplicación clara y sencilla de las pruebas de trazabilidad, descritas a continuación:

Como punto de partida, se encuentra el panel principal del módulo (

Fig. 2), que permite al personal médico acceder a las distintas opciones disponibles, entre ellas, el listado de pacientes registrados y el catálogo de pruebas.

En el listado de pacientes registrados, se muestra un resumen de la información de cada registro, permitiendo seleccionar al paciente con el que se encuentra trabajando. Cada paciente, cuenta su expediente, donde se registran los resultados de las pruebas realizadas y los datos clínicos relevantes, como se observa en la Fig. 3.

Determinada la selección del paciente, en el catálogo de pruebas (Fig. 4), se presentan las distintas categorías disponibles para la evaluación de la EP, enfocado para el caso de estudio las pruebas de trazabilidad.

Posterior a la selección de la prueba, el módulo presenta en pantalla un lienzo en blanco conformado por una serie de ejercicios, los cuales, se representan en plantillas de modelos de trazos en espiral y ondas, durante este proceso el paciente debe replicar la figura presentada con la mayor precisión posible tal como se observa en la Fig. 5, finalizando la prueba al concluir el último ejercicio aplicado.

Una vez finalizado el proceso de aplicación de la prueba, el médico obtiene un folio de seguimiento para la revisión de resultados, los cuales son accesibles desde el panel

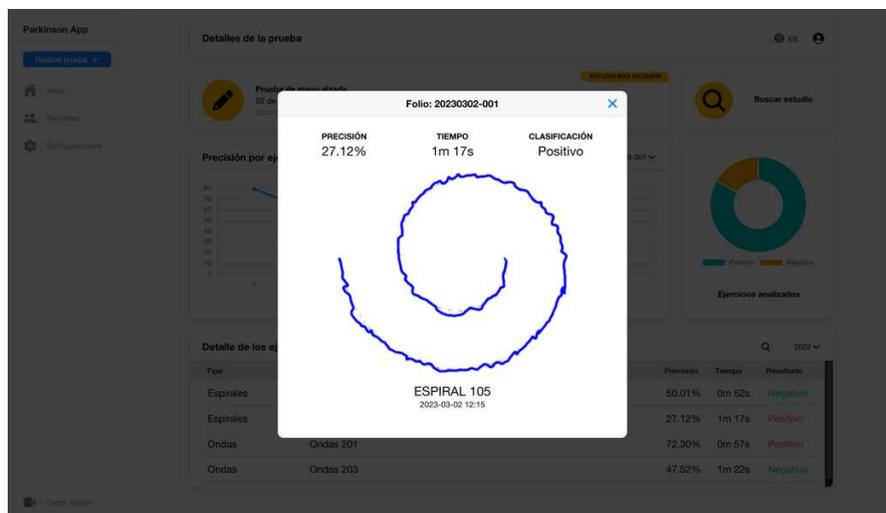


Fig. 6. Módulo web - Resultados de la prueba.

principal o panel del paciente, representando la vista previa del ejercicio y los resultados obtenidos por el clasificador, observado en la Fig. 6.

Es importante destacar que los resultados obtenidos son adecuados, esto se debe a la implementación de técnicas de AP que incorporan los procesos de clasificación para proporcionar resultados con mayor precisión, además, los algoritmos utilizados fueron seleccionados con base en métricas de rendimiento analizadas durante el proceso de estudio, determinando, así como modelo principal a los clasificadores: RF, SVM y GB.

Por otro lado, y como herramienta de apoyo en la toma de decisiones, cabe destacar que el valor de clasificación obtenido representa la probabilidad del padecimiento y no un resultado de diagnóstico determinante.

5. Conclusiones y trabajo a futuro

El enfoque en la detección temprana de la EP mediante técnicas de AP y con el desarrollo de un módulo web que permita incorporar los procesos de detección mediante ejercicios de trazabilidad, demostraron ser una herramienta efectiva, permitiendo a profesionales de salud, evaluar y clasificar con mayor precisión a los pacientes que presentan esta enfermedad.

Así mismo, la precisión obtenida por los algoritmos implementados (RF, SVM, y GB) permiten considerar al modelo como un recurso de gran importancia en el diagnóstico y seguimiento de la EP.

Como conclusiones se destacó que la utilización de técnicas de AP permite obtener resultados de mayor precisión y eficacia en comparación con métodos tradicionales. Además, el módulo desarrollado resultó ser una herramienta de gran utilidad para la detección temprana de la EP, así como también para el seguimiento en la evolución de los pacientes a lo largo del tiempo.

En cuanto a trabajo a futuro, se prevé expandir la capacidad del modelo presentado, mejorando su rendimiento para realizar estudios de clasificación a través de nuevos sistemas de información, tales como, el análisis de datos del lenguaje natural y la supervisión de la actividad motriz, así mismo, el modelo presentado se mantendrá como una plataforma enfocada en la identificación, diagnóstico y seguimiento de enfermedades crónicas y neurodegenerativas.

Finalmente, cabe mencionar que la incorporación de tecnologías de la información y técnicas de aprendizaje profundo en el sector de la salud, representan una herramienta valiosa para la detección de enfermedades, lo que brinda apertura y expansión a futuro de mejoras que permitan agilizar los procesos de diagnóstico de diversas enfermedades neurodegenerativas.

Agradecimientos. Este trabajo de investigación fue patrocinado por el Consejo Nacional de Ciencia y Tecnología de México (CONACYT) y la Secretaría de Educación Pública (SEP) de México a través del programa PRODEP. Los autores también agradecen al Tecnológico Nacional de México (TecNM) por apoyar este proyecto.

Referencias

1. Dorsey, E. R., Bloem, B. R.: The Parkinson endemic-A call to action. *JAMA Neurology*, vol. 75, no. 1, pp. 9–10 (2018) doi: 10.1001/jamaneurol.2017.3299
2. Instituto Nacional de Neurología y Neurocirugía: Enfermedad de Parkinson. INNN (2022) www.innn.salud.gob.mx/interna/medica/padecimientos/parkinson.html
3. Worasawate, D., Asawaponwiput, W., Yoshimura, N., Intarapanich, A., Surangsrirat, D.: Classification of Parkinson's disease from smartphone recording data using time-frequency analysis and convolutional neural network. *Technology and Health Care*, vol. 31, no. 2, pp. 705–718 (2023) doi: 10.3233/THC-220386
4. Punarselvam, E.: A pragmatic approach of Parkinson disease detection using hybrid case-based reasoning neuro-fuzzy classification system over mobile edge computing. *Journal of Intelligent and Fuzzy Systems*, vol. 44, no. 5, pp. 7653–7668 (2023) doi: 10.3233/JIFS-220941
5. Fraiwan, L., Khnouf, R., Mashagbeh, A. R.: Parkinson's disease hand tremor detection system for mobile application. *Journal of Medical Engineering and Technology*, vol. 40, no. 3, pp. 127–134 (2016) doi: 10.3109/03091902.2016.1148792
6. Zhang, H., Wang, A., Li, D., Xu, W.: DeepVoice: A voiceprint-based mobile health framework for Parkinson's disease identification. In: 2018 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI), pp. 214–217 (2018) doi: 10.1109/BHI.2018.8333407
7. Kuosmanen, E., Kan, V., Visuri, A., Vega, J., Nishiyama, Y., Dey, A., Harper, S., Ferreira, D.: Mobile-based monitoring of Parkinson's disease. In: Proceedings of the 17th International Conference on Mobile and Ubiquitous Multimedia, pp. 441–448 (2018) doi: 10.1145/3282894.3289737
8. Hu, J. Yuan, D. Z., Zhao, Q. Y., Wang, X. F., Zhang, X. T., Jiang, Q. H., Luo, H. R., Li, J., Ran, J. H., Li, J. F.: Acceptability and practicability of self-management for patients with Parkinson's disease based on smartphone applications in China. *BMC Medical Informatics Decision Making*, vol. 20, no. 183 (2020) doi: 10.1186/s12911-020-01187-x
9. Estévez, S., Cambroner, M. E., García-Ruiz, Y., Llana-Díaz, L.: Mobile applications for people with Parkinson's disease: A systematic search in app stores and content review.

JUCS - Journal of Universal Computer Science, vol. 25, no. 7, pp. 740–763 (2019) doi: 10.3217/jucs-025-07-0740

10. Linares-del-Rey, M., Vela-Desojo, L., Cano-Cuerda, R.: Aplicaciones móviles en la enfermedad de Parkinson: Una revisión sistemática. *Neurología*, vol. 34, no. 1, pp. 38–54 (2019) doi: 10.1016/j.nrl.2017.03.006
11. Kotsavasiloglou, C., Kostikis, N., Hristu-Varsakelis, D., Arnaoutoglou, M.: Machine learning-based classification of simple drawing movements in Parkinson's disease. *Biomedical Signal Processing and Control*, vol. 31, pp. 174–180 (2017) doi: 10.1016/j.bspc.2016.08.003
12. Camps, J., Samá, A., Martín, M., Rodríguez-Martín, D., Pérez-López, C., Arostegui, J. M., Cabestany, J., Catalá, A., Alcaine, S., Mestre, B., Prats, A., Crespo-Maraver, M. C., Counihan, T. J., Browne, P., Quinlan, L. R., Laighin, G., Sweeney, D., Lewy, H., Vainstein, G., Costa, A., et al.: Deep learning for freezing of gait detection in Parkinson's disease patients in their homes using a waist-worn inertial measurement unit. *Knowledge-Based Systems*, vol. 139, pp. 119–131 (2018) doi: 10.1016/j.knsys.2017.10.017
13. Alkhatib, R., Diab, M. O., Corbier, C., Badaoui, M. E.: Machine learning algorithm for gait analysis and classification on early detection of Parkinson. *IEEE Sensors Letters*, vol. 4, no. 6, pp. 1–4 (2020) doi: 10.1109/lSENS.2020.2994938
14. Rovini, E., Maremmani, C., Moschetti, A., Esposito, D., Cavallo, F.: Comparative motor pre-clinical assessment in Parkinson's disease using supervised machine learning approaches. *Annals of Biomedical Engineering*, vol. 46, no. 12, pp. 2057–2068 (2018) doi: 10.1007/s10439-018-2104-9
15. Moshkova, A., Samorodov, A., Voinova, N., Volkov, A., Ivanova, E., Fedotova, E.: Parkinson's disease detection by using machine learning algorithms and hand movement signal from LeapMotion sensor. In: 2020 26th Conference of Open Innovations Association, pp. 321–327 (2020) doi: 10.23919/fruct48808.2020.9087433
16. Yao, L., Brown, P., Shoaran, M.: Resting tremor detection in Parkinson's disease with machine learning and Kalman filtering. In: 2018 IEEE Biomedical Circuits and Systems Conference, pp. 1–4 (2018) doi: 10.1109/BIOCAS.2018.8584721
17. Anand, A., Haque, M. A., Alex, J. S., Venkatesan, N.: Evaluation of machine learning and deep learning algorithms combined with dimensionality reduction techniques for classification of Parkinson's disease. In: 2018 IEEE International Symposium on Signal Processing and Information Technology, pp. 342–347 (2018) doi: 10.1109/ISSPIT.2018.8642776
18. Wodzinski, M., Skalski, A., Hemmerling, D., Orozco-Arroyave, J. R., Noth, E.: Deep learning approach to Parkinson's disease detection using voice recordings and convolutional neural network dedicated to image classification. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 717–720 (2019) doi: 10.1109/EMBC.2019.8856972
19. Prashanth, R., Roy, S. D., Mandal, P. K., Ghosh, S.: High-accuracy detection of early Parkinson's disease through multimodal features and machine learning. *International Journal of Medical Informatics*, vol. 90, pp. 13–21 (2016) doi: 10.1016/j.ijmedinf.2016.03.001
20. Arora, S., Venkataraman, V., Zhan, A., Donohue, S., Biglan, K., Dorsey, E., Little, M.: Detecting and monitoring the symptoms of Parkinson's disease using smartphones: A pilot study. *Parkinsonism and Related Disorders*, vol. 21, no. 6, pp. 650–653 (2015) doi: 10.1016/j.parkreldis.2015.02.026
21. Ali, L., Zhu, C., Golilarz, N. A., Javeed, A., Zhou, M., Liu, Y.: Reliable Parkinson's disease detection by analyzing handwritten drawings: Construction of an unbiased cascaded learning system based on feature selection and adaptive boosting model. *IEEE Access*, vol. 7, pp. 116480–116489 (2019) doi: 10.1109/ACCESS.2019.2932037

22. Senturk, Z. K.: Early diagnosis of Parkinson's disease using machine learning algorithms. *Medical Hypotheses*, vol. 138 (2020) doi: 10.1016/j.mehy.2020.109603
23. Haq, A. U., Li, J., Memon, M. H., Khan, J., Din, S. U., Ahad, I., Sun, R., Lai, Z.: Comparative analysis of the classification performance of machine learning classifiers and deep neural network classifier for prediction of Parkinson disease. In: 2018 15th International Computer Conference on Wavelet Active Media Technology and Information Processing, pp.101–106 (2018) doi: 10.1109/iccwamtip.2018.8632613
24. Pahuja, G., Nagabhushan, T. N.: A comparative study of existing machine learning approaches for Parkinson's disease detection. *IETE Journal of Research*, vol. 67, no. 1, pp. 4–14 (2018) doi: 10.1080/03772063.2018.1531730
25. Nilashi, M., Ibrahim, O., Ahmadi, H., Shahmoradi, L., Farahmand, M.: A hybrid intelligent system for the prediction of Parkinson's disease progression using machine learning techniques. *Biocybernetics and Biomedical Engineering*, vol. 38, no. 1, pp. 1–15 (2018) doi: 10.1016/j.bbe.2017.09.002
26. Griffith, C.: What is hybrid mobile app development? (2021) ionic.io/resources/articles/what-is-hybrid-app-development/
27. Griffith, C.: *Mobile app development with ionic: Cross-platform apps with ionic, angular, and cordova*. O'Reilly Media (2017)
28. Grinberg, M.: *Flask web development: Developing web applications with Python*. O'Reilly Media (2018)
29. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E.: Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, vol. 12, no. 85, pp. 2825–2830 (2011)