

Tipo de artículo : Artículo original
Temática : Inteligencia artificial y reconocimiento de patrones.

Módulo Inteligente para la clasificación y explicación de Úlceras de Pie Diabético (UPD)

Intelligent Module for the classification and explanation of Diabetic Foot Ulcers (DFU)

Dailys Pilar Oliver Borrero^{1*} <https://orcid.org/0009-0009-3418-6628>

María Matilde García Lorenzo¹ <https://orcid.org/0000-0002-1663-5794>

Yusely Ruiz Gonzalez¹ <https://orcid.org/0000-0002-6011-1947>

Rosalís Amador García¹ <https://orcid.org/0009-0003-9334-3079>

Alexy Matamoros Andreu² <https://orcid.org/0009-0000-6927-7049>

Cecilio González Benavidez³ <https://orcid.org/0000-0003-4690-661X>

¹ Centro de Investigaciones de la Informática, Universidad Central "Marta Abreu" de Las Villas, Carretera a Camajuani km 8 ½, Villa Clara, Cuba.

²Hospital Provincial Arnaldo Milián Castro, Avenida "Arnaldo Milián Castro" e/ Circunvalación y Doble Vía, Villa Clara, Cuba.

³Cardiocentro Ernesto Guevara de la Serna, Calle Cuba No. 610 e/ Barcelona y Capitán Velazco Villa Clara, Cuba.

*Autor para la correspondencia. (dpob0305@gmail.com)

RESUMEN

Las úlceras en el pie diabético son una complicación común y grave en pacientes con diabetes, que se presentan como llagas abiertas o heridas en la planta del pie y mal atendidas pueden conducir a la amputación e incluso provocar la muerte. Por ello, es crucial continuar investigando y creando herramientas que faciliten un diagnóstico temprano y preciso de esta complicación. Con este fin, se implementó una aplicación dirigida a especialistas y desarrolladores, que permite detectar, clasificar y explicar zonas relevantes de las UPD. Se utilizaron datos del DFU Challenge 2021, se aplicaron técnicas de balanceo de clases y transferencia de aprendizaje en el entrenamiento de los modelos y se realizaron diversas pruebas con datos del hospital provincial “Arnaldo Milián Castro”, obteniendo resultados favorables en la clasificación de imágenes. Los mejores resultados se obtuvieron con el modelo de clasificación Vision Transformer. Además, el módulo de explicación desarrollado favorece la interpretación de los resultados alcanzados en la clasificación. Se obtuvo la versión 2.0 del software “Cuidado Inteligente del Pie Diabético” con funcionalidades superiores a la versión anterior.

Palabras Clave: úlceras en el pie diabético; DFU Challenge; Vision Transformer; clasificación; CNN; módulo de explicación.

ABSTRACT

Diabetic foot ulcers (DFUs) are a common and serious complication in patients with diabetes. They present as open sores or wounds on the soles of the feet and, if left untreated, can lead to amputation and even death. Therefore, it is crucial to continue researching and developing tools that facilitate early and accurate diagnosis of this complication. To this end, an application was implemented for specialists and developers, enabling the detection, classification, and explanation of relevant areas of DFUs. Data from the DFU Challenge 2021 was used, applying class balancing and transfer learning techniques to train the models. Various tests were conducted using data from the "Arnaldo Milián Castro" Provincial Hospital, yielding favorable results in image classification. The Vision Transformer classification model and the developed explanation module, which facilitates the interpretation of the classification results, were particularly

noteworthy. Version 2.0 of the "Intelligent Diabetic Foot Care" software was released, offering enhanced functionalities compared to the previous version.

Keywords: Diabetic foot ulcers, DFU Challenge, Vision Transformer, classification, CNN, explanation module

Recibido: 16/09/2025

Aceptado: 20/02/2026

Publicado: 01/04/2026

Introducción

Las úlceras del pie diabético (UPD) son una complicación común y grave en pacientes con diabetes, que se presenta como llagas abiertas o heridas en la planta del pie. Son el resultado de la alteración de la circulación sanguínea y la neuropatía asociada con la diabetes, lo que aumenta el riesgo de infecciones graves. Las úlceras del pie diabético pueden ser superficiales o profundas y requieren atención especializada para asegurar que cicatricen correctamente y prevenir complicaciones. La detección temprana, el cuidado eficaz de las heridas y el control de la diabetes son cruciales para prevenir y tratar las UPD, el diagnóstico clínico y un sistema de clasificación que establezca el estado de la úlcera, son parámetros importantes para evaluar la gravedad de la misma. Por lo tanto, es necesaria una clasificación de UPD validada y apropiada que permita evaluar la evolución clínica de la lesión, lo cual es esencial para el seguimiento, la identificación de cambios significativos y la aplicación de un tratamiento oportuno. Unas úlceras mal atendidas pueden conducir a la amputación del miembro del paciente e incluso provocar su muerte (Arias-Rodríguez et al. 2023).

La inteligencia artificial (IA) ha revolucionado el diagnóstico y el tratamiento de las UPD mediante técnicas de aprendizaje profundo y visión computacional (Stryker y Caballar, 2025). Estas técnicas permiten detectar úlceras en etapas tempranas mediante el análisis de imágenes, lo que mejora las tasas de curación y reduce el riesgo de complicaciones (Cassidy et al. 2021). En este contexto, (Ruiz-González et al. 2025) exploraron el

uso de técnicas de aprendizaje profundo para la detección y clasificación automática de UPD y como resultado, se implementó un sistema inteligente para la clasificación de lesiones de UPD, registrado como “Cuidado Inteligente del Pie Diabético versión 1.0” («UPDStreamlit», 2024). La versión implementada incluye un módulo de captación y pre-procesamiento de la imagen del pie del paciente, en la detección de las lesiones utiliza el modelo de detección de objetos YOLOv8l (Yaseen, 2024) con un mAP50 (Cochard, 2021) de 79.9% y en el módulo de clasificación de las distintas lesiones utiliza la red convolucional DenseNet201 («DenseNet Explained» 2024) que reporta una eficacia en entrenamiento de 97% con una pérdida del 23%, 94% de eficacia en validación con una pérdida del 45% y 45.45% de eficacia en el conjunto de prueba. Ambos modelos fueron entrenados con las bases de datos liberadas durante los *DFU Challenge* 2020 (detección) (Cassidy et al. 2021) y 2021 (clasificación) (Wu et al. 2022).

La propuesta inicial presenta como deficiencias altos valores de pérdidas durante la etapa de validación y una eficacia alrededor de 50 % en la prueba externa lo que genera la sospecha de que confunde las imágenes de personas de piel oscura, esto debido a que fue entrenado solamente con imágenes de piel blanca. También pudiera existir un sobreajuste del modelo clasificador lo cual subraya la urgencia de implementar técnicas de Inteligencia Artificial Explicable (XAI), que podría ayudar a identificar si el modelo está basando sus decisiones en características relevantes de la úlcera (tamaño, color, profundidad) o en atributos irrelevantes como el tono de piel del paciente, permitiendo corregir este sesgo y garantizar una atención equitativa (Vaquero de Miguel, 2020). Este campo de investigación dentro de la IA busca hacer transparentes y comprensibles para los humanos los procesos de toma de decisiones de los modelos mediante el uso de un conjunto de procedimientos, técnicas y métodos y emerge como una herramienta esencial para desentrañar los mecanismos internos de estos y garantizar su aplicación ética y efectiva.

Una vez aplicadas las técnicas correspondientes de XAI al modelo de clasificación de UPD, sería ideal mejorar este modelo basándose en las revelaciones obtenidas. Al comprender cómo el modelo llega a sus decisiones, se pueden identificar áreas de mejora específicas. Esto permitiría ajustar el modelo para que sea más inclusivo y preciso, reduciendo el riesgo de sesgos discriminatorios y mejorando la equidad en el diagnóstico (Goyal et al. 2020). Además, la XAI podría ayudar a revelar qué características de las úlceras son más relevantes para la clasificación, lo que podría conducir a una mejor comprensión de la patología (Tjoa y Guan, 2021).

A partir de lo analizado se propone desarrollar una herramienta inteligente de ayuda a la toma de decisiones para la clasificación de UPD eficaz y explicable, dirigido hacia la clasificación y explicación de imágenes.

Metodología Computacional

La investigación se apoya en un conjunto de imágenes de úlceras de pie diabético (UPD) procedentes del reto *DFU Challenge 2021* (Wu et al. 2022) para realizar el entrenamiento y validación del modelo. El conjunto de datos inicial luego de los pertinentes procesos de generación y limpieza se divide en 80% para entrenamiento y 20% para validación. Adicionalmente, se utiliza un conjunto de prueba externa proporcionado por el Hospital Provincial Arnaldo Milián Castro, compuesto por 49 imágenes anotadas y clasificadas por especialistas en angiología.

El preprocesamiento de las imágenes incluyó técnicas de aumento de datos mediante la biblioteca *ImageDataGenerator* de Keras, aplicando transformaciones como rotaciones, desplazamientos horizontales y verticales, cambios de perspectiva, *zoom*, reflejos horizontales y ajustes de brillo, contraste y saturación. Estas técnicas se aplicaron exclusivamente a las clases minoritarias (*ischaemia* y *both*) del conjunto de entrenamiento para mitigar el desbalance de clases que presenta y mejorar la capacidad de generalización de los modelos. Además, se eliminaron duplicados en las clases mayoritarias (*infection* y *none*). El conjunto de validación se mantuvo sin transformaciones para preservar la evaluación objetiva del modelo ya que se corre el riesgo de alterar su naturaleza original, lo que podría llevar a una evaluación engañosa de la capacidad del modelo para generalizar.

Este enfoque de preprocesamiento representó una mejora sustancial respecto al trabajo previo (Ruíz Jiménez, 2024), donde la aplicación inapropiada de SMOTE («SMOTE» 2021), técnica diseñada para datos tabulares, generó muestras sintéticas visualmente inconsistentes, y el uso de validación cruzada (Brownlee 2023) sin una separación estricta entre variantes de una misma imagen introdujo contaminación entre los conjuntos de entrenamiento y validación. Estas limitaciones metodológicas explican el bajo rendimiento y la

escasa generalización del modelo DenseNet201 reportado en dicho estudio, el cual, a pesar de mostrar métricas excelentes durante la validación (F1-Score: 0.97), presentó una exactitud de sólo el 43% en el conjunto de prueba externo, con una alta confusión entre clases, especialmente entre *none* e *infection*, y un desempeño particularmente deficiente en imágenes de pacientes con tonos de piel más oscuros.

Para superar estas limitaciones de generalización y capturar relaciones contextuales más complejas en las imágenes, en esta investigación se optó por evaluar y comparar un espectro más amplio de arquitecturas profundas. Se experimentó con redes neuronales convolucionales (CNN) (Kelta, 2024) como GoogLeNet, VGG16, VGG19, ResNet50, DenseNet201 y MobileNetV2, y se incorporaron arquitecturas basadas en *Transformers* (*Vision Transformer*, *Swin Transformer*, *ConViT*) (Ibrahim 2024), conocidas por su capacidad para modelar dependencias de largo alcance mediante mecanismos de auto-atención (Torre 2023). Los modelos se implementaron usando *TensorFlow/Keras* y la biblioteca *Hugging Face Transformers* (<https://huggingface.co>), aplicando transferencia de aprendizaje (Sakamoto, 2023) a partir de pesos preentrenados en ImageNet (<https://www.image-net.org>). Se realizó una búsqueda de hiperparámetros, optimizando el número de épocas y el tamaño del lote. Los modelos se evaluaron mediante las métricas precisión (*accuracy*), pérdida (*loss*), sensibilidad (*recall*) y *F1-Score* (Singh Chauhan, 2023).

Dada la naturaleza de “cajas negras” de estos modelos, se incorpora un módulo de explicabilidad utilizando métodos agnósticos como LIME y SHAP, así como el método dependiente del modelo *Attention Visualization*, nativo de los *Transformers*. LIME genera explicaciones locales mediante perturbaciones y modelos lineales interpretables (Ribeiro, Singh y Guestrin, 2016), mientras que SHAP utiliza valores de Shapley para cuantificar la contribución de cada región de la imagen (Staffel, 2024). Por su parte, la visualización de atención permite identificar las regiones más relevantes directamente desde los mecanismos de auto-atención del ViT, mostrando una mayor estabilidad y coherencia clínica (Hatamizadeh et al. 2022). De esta manera, se busca resaltar las regiones de las imágenes que más influyen en la predicción del modelo, lo que permite detectar posibles sesgos o errores.

Finalmente, la calidad de las explicaciones se evaluó mediante la métrica de Fidelidad (IyMagazine, 2025), que cuantifica el grado en que las explicaciones reflejan fielmente el proceso de decisión del modelo. Con ello se garantiza que la herramienta no solo clasifique con precisión, sino que también ofrezca interpretaciones comprensibles y útiles para especialistas médicos.

Resultados y discusión

Entrenamiento

El conjunto de datos inicial se compone por 616 imágenes de la clase *both*, 2511 de *infection*, 218 de *ischaemia* y 2517 de *none*. Aunque se procuró el mayor balance entre categorías mediante técnicas de aumento de datos aplicadas a las clases minoritarias y la eliminación de duplicados en las mayoritarias, la disponibilidad de imágenes siguió siendo limitada, El conjunto de entrenamiento final estuvo conformado por 1778 imágenes de la clase *both*, 1926 de *infection*, 1560 de *ischaemia* y 1866 de *none*. El conjunto de validación, sin transformaciones adicionales, quedó integrado por 125 imágenes en *both*, 502 en *infection*, 44 en *ischaemia* y 504 en *none*, garantizando así una evaluación objetiva.

En una primera fase, se entrenaron diversas arquitecturas de CNN: VGG16, VGG19, Inception V3, DenseNet201 y ResNet50. Como se muestra en la Tabla 1, si bien modelos como DenseNet201 y VGG19 alcanzaron alta exactitud en entrenamiento (94.5% y 89.1%, respectivamente), su rendimiento en validación fue considerablemente inferior (63.8% y 63.9%), lo que evidenció un marcado sobreajuste. En contraste, ResNet50 mostró un mejor equilibrio, con 68.4% de exactitud en validación y una pérdida de 0.74, constituyéndose en la CNN más estable frente a datos no vistos.

Tabla 1- Resultado de los diferentes modelos CNN

Modelo CNN	Exactitud en Entrenamiento	Pérdida en Entrenamiento	Exactitud en Validación	Pérdida en Validación
VGG16	0.7073	3.6108	0.5838	3.8875
VGG19	0.8916	0.3038	0.6391	0.8321

ResNet50	0.8950	0.5051	0.6843	0.7433
InceptionV3	0.9153	0.2841	0.6409	0.8678
DenseNet201	0.9454	0.4762	0.6383	0.8376

Posteriormente, se evaluaron arquitecturas basadas en Transformers, optimizadas mediante búsqueda de hiperparámetros. Los resultados (Tabla 2) evidenciaron una mejora sustancial respecto a las CNN. *El Vision Transformer (ViT)* alcanzó la mayor exactitud en validación (72.2%), acompañado de una pérdida reducida (0.45) y métricas balanceadas en sensibilidad (71.9%) y F1-Score (71.8%). El *Swin Transformer* obtuvo un rendimiento cercano (71.4% de exactitud, pérdida de 0.40), mientras que el *ConViT*, aunque competitivo en exactitud (70.2%), presentó una pérdida más alta (1.03), lo que indicó menor estabilidad.

Tabla 2 - Resultados de los diferentes modelos Transformer

Modelo	Exactitud en Entrenamiento	Exactitud en Validación	Pérdida Validación	Sensibilidad	F1-Score
ViT	0.9988	0.7223	0.4524	0.7191	0.7175
Swin Transformer	0.9705	0.7145	0.4040	0.7140	0.7139
ConViT	0.9974	0.7021	1.0396	0.7011	0.7008

En síntesis, aunque ResNet50 fue la CNN con mejor desempeño, los *Transformers* demostraron una mayor capacidad de generalización y robustez, destacándose el ViT como el modelo óptimo. La reducción de la pérdida de validación al pasar de CNN a *Transformers* confirma que estas arquitecturas logran capturar relaciones de mayor alcance en las imágenes, traduciéndose en una clasificación más precisa y consistente de las úlceras de pie diabético.

El *Vision Transformer* (vit-base-patch16-224), tras la búsqueda de hiperparámetros, se consolidó como el mejor modelo, superando ampliamente los resultados previos reportados con DenseNet201 (Ruíz Jiménez, 2024). La implementación del preprocesamiento descrito, junto con la división manual del conjunto para evitar contaminación entre entrenamiento y validación, permitió alcanzar un entrenamiento más estable y generalizable.

El modelo seleccionado fue evaluado en un conjunto de prueba externa del Hospital Provincial Arnaldo Milián Castro, compuesto por 49 imágenes, entre ellas pies sanos para probar la efectividad del modelo de detección, el cual tuvo como salida 37 lesiones segmentadas, las cuales son clasificadas por especialistas en angiología. En este escenario clínico real, el ViT obtuvo una exactitud global del 57%, con un desempeño sobresaliente en las clases *both* (sensibilidad del 100%) e *ischaemia* (sensibilidad del 100%). La clase *infection*, la más representada, alcanzó una sensibilidad del 73%, mientras que *none* presentó mayor dificultad (sensibilidad del 20%), aunque con una precisión del 75%. La comparación directa con DenseNet201 (Figura 1), que en este mismo conjunto alcanzó solo un 43% de exactitud, evidencia la mejora sustancial en la capacidad de generalización del enfoque de *Transformer* propuesto.

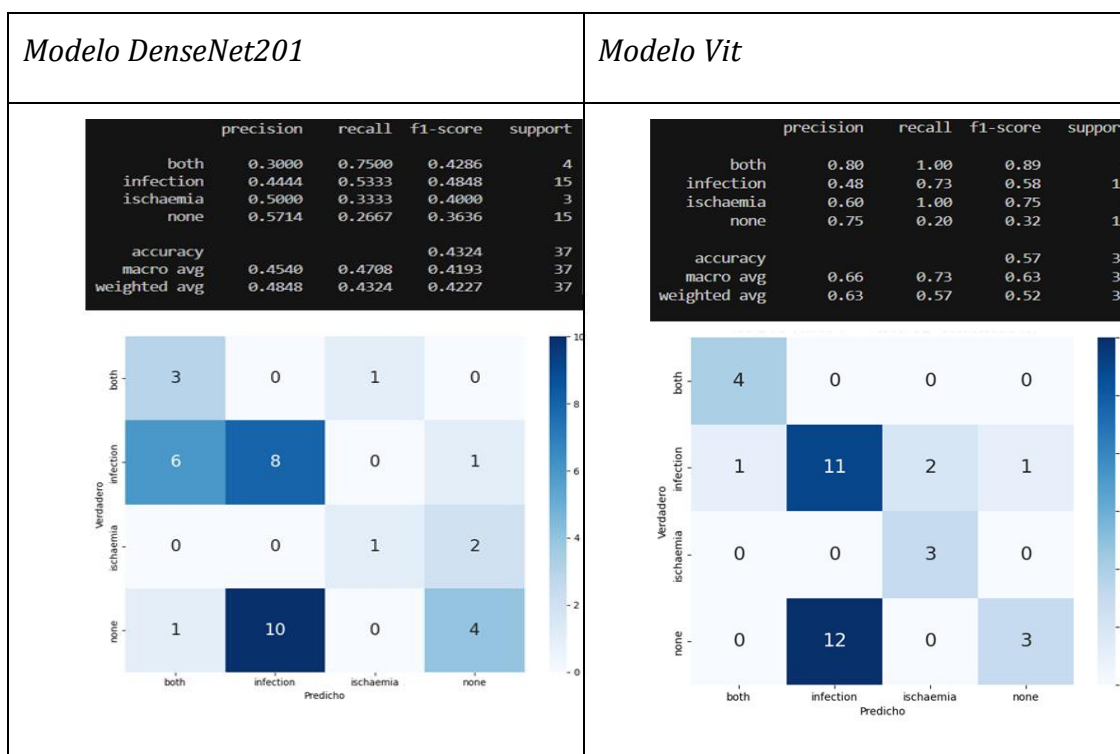


Fig. 1 - Matrices de confusión durante la prueba externa con modelo DenseNet201y Vit

Aplicación de la explicabilidad

Una vez identificado el *Vision Transformer* (ViT) como el modelo de mejor desempeño en términos de clasificación, se procedió a evaluar el módulo de explicabilidad, con el objetivo de analizar la fidelidad de las explicaciones generadas y su utilidad en la interpretación clínica. En el conjunto de validación, los métodos LIME y SHAP alcanzaron fidelidades de 0.6979 y 0.8544, respectivamente, evidenciando un desempeño aceptable en la representación de las decisiones del modelo. Sin embargo, la visualización de atención superó ampliamente estos resultados, con una fidelidad de 0.9455, mostrando mayor estabilidad y coherencia en la identificación de las regiones relevantes de la imagen (Figura 2). Este comportamiento se confirmó en el conjunto de prueba externa, donde la visualización de atención alcanzó una fidelidad aún mayor (0.9939), superando de manera consistente a LIME y SHAP. Estos hallazgos no solo destacan la superioridad del enfoque basado en atención frente a los métodos agnósticos, sino que también refuerzan su pertinencia clínica, al ofrecer explicaciones más alineadas con los criterios médicos utilizados en la práctica especializada.



Fig. 2 - Aplicación de Attention Visualization, las regiones en rojo indican las zonas donde el modelo enfocó mayor atención al tomar su decisión, el grado de intensidad del color indica el grado de enfoque.

Actualización de la aplicación

En trabajos previos, se desarrolló una primera versión de la aplicación de apoyo al diagnóstico de úlceras de pie diabético. Esta propuesta integraba un detector YOLOv8 para localizar la lesión y un clasificador basado en DenseNet201 para determinar su tipo. La presente investigación dio lugar a la versión 2.0 de la aplicación web “Cuidado Inteligente del Pie Diabético”, en la cual se incorporaron las mejoras obtenidas durante el

proceso experimental. En primer lugar, el clasificador DenseNet201 fue reemplazado por el *Vision Transformer* (ViT), seleccionado por su mayor poder de generalización y estabilidad frente a la variabilidad de los datos, especialmente en pacientes con distintos tonos de piel. Además, se añadió por primera vez un módulo de explicabilidad con la visualización de atención propia de los Transformers, lo que permite identificar las regiones de la imagen más relevantes para la predicción y proporciona interpretaciones coherentes con el criterio médico.

Finalmente, la aplicación fue rediseñada sobre *Streamlit*, con una interfaz intuitiva que permite cargar imágenes, ajustar el umbral de confianza del detector YOLOv8, visualizar las clasificaciones y superponer los mapas de atención sobre las lesiones detectadas (Figura 3). Estas mejoras convierten a la versión 2.0 en una herramienta más confiable, robusta y transparente, que integra clasificación precisa con explicaciones interpretables, respondiendo a las demandas prácticas del ámbito clínico.

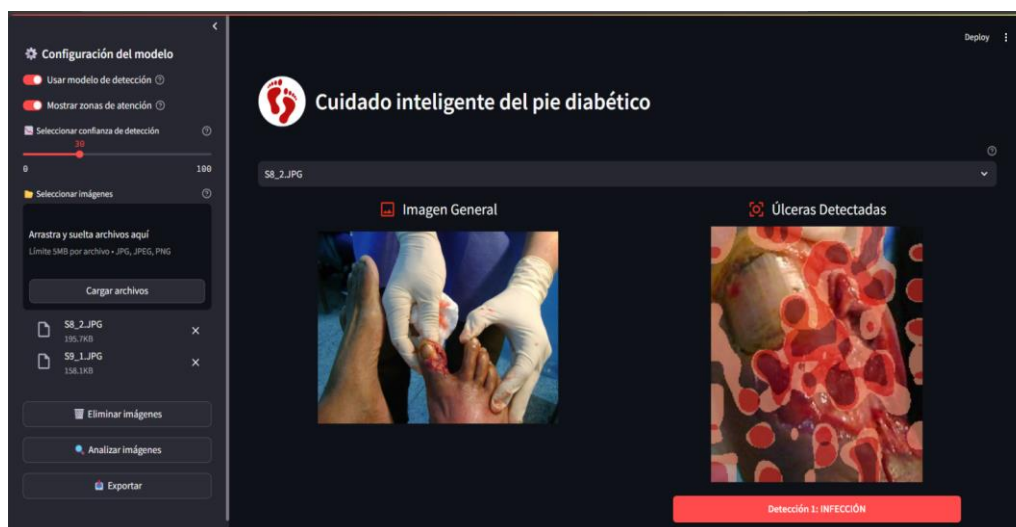


Fig. 3 - Interfaz de usuario de la versión 2.0 de la aplicación, mostrando la imagen original, las detecciones, la clasificación y las áreas de atención.

Conclusiones

Los resultados obtenidos demuestran que el *Vision Transformer* (ViT) no solo supera en capacidad de generalización al enfoque anterior, sino que, gracias a su mecanismo de atención inherente, ofrece explicaciones de alta fidelidad. La integración de estas mejoras en una aplicación web robusta, precisa e interpretable constituye un avance significativo como herramienta de apoyo al diagnóstico clínico, combinando potencia predictiva con transparencia en la toma de decisiones.

Referencias

- Arias-Rodríguez, F.D., Jiménez-Valdiviezo, M.A., Del Cisne-Ríos-Criollo, K., Murillo-Araujo, G.P., Toapanta-Allauca, D.S., Rubio-Laverde, K.A., Barreno-Yandún, Y.P., Moposita-Alvarado, M.M. Y Trejo-Pincay, M.B., 2023. Pie Diabético. Actualización En Diagnóstico Y Tratamiento. Revisión Bibliográfica. *Angiología*, Vol. 75, No. 4, Pp. 242-258. Issn 0003-3170. Doi 10.20960/Angiologia.00474.
- Brownlee, P.J., 2023. Una Breve Introducción A La Validación Cruzada De K-Fold - Machinelearningmastery.Com. [En Línea]. [Consulta: 6 Abril 2025]. Disponible En: <https://Machinelearningmastery.Com/K-Fold-Cross-Validation/>.
- Cassidy, B., Reeves, N.D., Pappachan, J.M., Gillespie, D., O'shea, C., Rajbhandari, S., Maiya, A.G., Frank, E., Boulton, A.J.M., Armstrong, D.G., Najafi, B., Wu, J., Kochhar, R.S. Y Yap, M.H., 2021. The Dfuc 2020 Dataset: Analysis Towards Diabetic Foot Ulcer Detection. *Touchreviews En Endocrinología*, Vol. 17, Pp. 5-11. Doi <https://doi.org/10.17925/Ee.2021.17.1.5>.
- Cochard, D., 2021. Map: Evaluation Metric For Object Detection Models. *Axinc-Ai* [En Línea]. [Consulta: 21 Marzo 2025]. Disponible En: <https://medium.com/Axinc-Ai/Map-Evaluation-Metric-Of-Object-Detection-Model-Dd20e2dc2472>.
- Densenet Explained. *Geeksforgeeks* [En Línea], 2024. [Consulta: 7 Marzo 2025]. Disponible En: <https://www.geeksforgeeks.org/Densenet-Explained/>.

Goyal, M., Reeves, N., Rajbhandari, S., Ahmad, N., Wang, C. Y Yap, M.H., 2020. Recognition Of Ischaemia And Infection In Diabetic Foot Ulcers: Dataset And Techniques. En: Arxiv:1908.05317 [Eess], *Computers In Biology And Medicine*, Vol. 117, Pp. 103616. Issn 00104825. Doi 10.1016/J.Compbimed.2020.103616.

Hatamizadeh, A., Tang, Y., Nath, V., Yang, D., Myronenko, A., Landman, B., Roth, H.R. Y Xu, D., 2022. Unetr: Transformers For 3d Medical Image Segmentation. *Proceedings Of The Ieee/Cvf Winter Conference On Applications Of Computer Vision* [En Línea]. S.L.: S.N., Pp. 574-584. [Consulta: 14 Junio 2025]. Disponible En: https://openaccess.thecvf.com/content/Wacv2022/html/Hatamizadeh_Unetr_Transformers_For_3d_Medical_Image_Segmentation_Wacv_2022_Paper.html.

Ibrahim, M., 2024. Historia De Los Modelos De Visión. [En Línea]. [Consulta: 22 Febrero 2025]. Disponible En: <https://www.ultralytics.com/es/blog/a-history-of-vision-models>.

Iymagazine, 2025. Estudio De La Uib Propone Nuevas Métricas Para Evaluar La Fidelidad En Inteligencia Artificial Explicable. *Iymagazine* [En Línea]. [Consulta: 27 Marzo 2025]. Disponible En: <https://iymagazine.es/noticia/6572/tecnologia/estudio-de-la-uib-propone-nuevas-metricas-para-evaluar-la-fidelidad-en-inteligencia-artificial-explicable.html>.

Kelta, Z., 2024. Introducción A Las Redes Neuronales Convolucionales: Guía Completa De Las Cnn En El Aprendizaje Profundo. [En Línea]. [Consulta: 7 Marzo 2025]. Disponible En: <https://www.datacamp.com/tutorial/introduction-to-convolutional-neural-networks-cnns>.

Ribeiro, M.T., Singh, S. Y Guestrin, C., 2016. «Why Should I Trust You?»: Explaining The Predictions Of Any Classifier. *Proceedings Of The 22nd Acm Sigkdd International Conference On Knowledge Discovery And Data Mining* [En Línea]. San Francisco California Usa: S.N., Pp. 1135-1144. [Consulta: 12 Marzo 2025]. Isbn 978-1-4503-4232-2. Doi 10.1145/2939672.2939778. Disponible En: <https://dl.acm.org/doi/10.1145/2939672.2939778>.

Ruíz Jiménez, R., 2024. *Clasificación De La Úlcera De Pie Diabético Utilizando Inteligencia Artificial*. Tesis De Grado. S.L.: Uclv.

Ruiz-González, Y., Cáceres, E.M., García Lorenzo, M.M., Andreu, A.M. Y Benavidez, C.G., 2025. Detection Of Diabetic Foot Ulcers Using Deep Learning Models. En: J.C. Figueroa-García, J.A. López-

Sotelo, J.F. Moreno-Trujillo Y E.E. Gaona-García (Eds.), *Applied Computer Sciences In Engineering*. Cham: Springer Nature Switzerland, Pp. 308-319. Isbn 978-3-032-08203-9. Doi 10.1007/978-3-032-08203-9_26.

Sakamoto, A., 2023. Hugging Face Transformers: Tu Puerta De Entrada A La Última Tecnología En Procesamiento Del Lenguaje Natural –. *Kanaries* [En Línea]. [Consulta: 23 Junio 2025]. Disponible En: <https://docs.kanaries.net/es/topics/chatgpt/hugging-face-transformers>.

Singh Chauhan, N., 2023. Métricas De Evaluación De Modelos En El Aprendizaje Automático. *Datasource.Ai* [En Línea]. [Consulta: 1 Octubre 2025]. Disponible En: <https://www.datasource.ai/es/data-science-articles/view-source:https://www.datasource.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico>.

Smote. *Data Science* [En Línea], 2021. [Consulta: 9 Marzo 2025]. Disponible En: <https://staging7.datascience.eu/es/programacion/smote/>.

Staffel, N., 2024. A Primer On Shap (Shapley Additive Explanations). [En Línea]. [Consulta: 13 Marzo 2025]. Disponible En: <https://www.revenantresearch.com/p/a-primer-on-shap-shapley-additive>.

Stryker, C. Y Caballar, R.D., 2025. What Is Computer Vision? | IBM. [En Línea]. [Consulta: 31 Enero 2026]. Disponible En: <https://www.ibm.com/think/topics/computer-vision>.

Tjoa, E. Y Guan, C., 2021. A Survey On Explainable Artificial Intelligence (Xai): Toward Medical Xai. *Ieee Transactions On Neural Networks And Learning Systems*, Vol. 32, No. 11, Pp. 4793-4813. Issn 2162-2388. Doi 10.1109/Tnnls.2020.3027314.

Torre, J. De La, 2023. *Transformadores: Fundamentos Teóricos Y Aplicaciones* [En Línea]. 18 Febrero 2023. S.L.: Arxiv. [Consulta: 21 Abril 2025]. Arxiv:2302.09327. Disponible En: <http://arxiv.org/abs/2302.09327>.

Upstreamlit. [En Línea], 2024. [Consulta: 7 Marzo 2025]. Disponible En: <https://upd-ai.streamlit.app/>.

Vaquero De Miguel, G., 2020. *Aproximaciones A La Explicación De Decisiones Algorítmicas: Inteligencia Artificial Explicable* [En Línea]. Trabajo Fin De Grado / Proyecto Fin De Carrera. Madrid, España: E.T.S. De Ingenieros Informáticos (Upm). [Consulta: 14 Junio 2025]. Disponible En: <https://oa.upm.es/63381/>.

Wu, X., Liu, R., Wen, Q., Ao, B. Y Li, K., 2022. Dfuc2021 Dataset Classification Based On Deep Semi-Supervised Learning Methods. *2022 2nd International Conference On Consumer Electronics And Computer*

Engineering (Iccece) [En Línea]. S.L.: S.N., Pp. 499-502. [Consulta: 28 Marzo 2025]. Doi 10.1109/Iccece54139.2022.9712776. Disponible En: <https://ieeexplore.ieee.org/document/9712776>.

Yaseen, M., 2024. *What Is Yolov8: An In-Depth Exploration Of The Internal Features Of The Next-Generation Object Detector* [En Línea]. 28 Agosto 2024. S.L.: Arxiv. [Consulta: 7 Marzo 2025]. Arxiv:2408.15857. Disponible En: <http://arxiv.org/abs/2408.15857>.

Conflicto de interés

El autor autoriza la distribución y uso de su artículo.

Contribuciones de los autores

Conceptualización: Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez, María Matilde García Lorenzo.

Curación de datos: Alexy Matamoros Andreu, Cecilio González Benavidez, Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez

Análisis formal: Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez, María Matilde García Lorenzo, Rosalís Amador García

Adquisición de fondos: Yusely Ruiz-Gonzalez

Investigación: Dailys Pilar Oliver Borrero

Metodología: Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez, María Matilde García Lorenzo

Administración del proyecto: Yusely Ruiz-Gonzalez

Recursos: Cecilio González Benavidez, Yusely Ruiz-Gonzalez

Software: Dailys Pilar Oliver Borrero, Rosalís Amador García

Supervisión: Yusely Ruiz-Gonzalez, María Matilde García Lorenzo, Rosalís Amador García

Validación: Alexy Matamoros Andreu, Cecilio González Benavidez, María Matilde García Lorenzo

Visualización Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez, Rosalís Amador García

Redacción – borrador original –: Dailys Pilar Oliver Borrero, Yusely Ruiz-Gonzalez

Redacción – revisión y edición-: María Matilde García Lorenzo, Rosalís Amador García, Cecilio González Benavidez

Financiación

Esta investigación fue financiada gracias a la Oficina De Gestión de Fondos y Proyectos Internacionales bajo el código PN223LH004-039 y el Programa Territorial del CITMA Salud Humana bajo el código PT241VC001-009