




Deep Learning Models for the Early and Effective Detection of Diabetes Through Foot Images: A Systematic Review

Derick Andy Bonilla Regalo, Bachelor's student¹; Javier Benjhamy De la Cruz Sanchez, Bachelor's student²;
Lourdes Milagrito Alegría La Rosa de Benavides, Magister³
^{1,3}Universidad Tecnológica del Perú, Perú, U20213095@utp.edu.pe, c11071@utp.edu.pe
²Universidad Tecnológica del Perú, Perú, U20220253@utp.edu.pe

Abstract– This Systematic Literature Review (SLR), conducted under the PRISMA methodology, aims to identify recently proposed artificial intelligence models for the early identification of diabetes patients through foot images. It analyzes the challenges these models address, the Deep Learning (DL) techniques utilized, and the performance metrics applied. Additionally, the results obtained are examined, highlighting innovations compared to classical methods. Out of 237 articles identified in SCOPUS using the PICO methodology, 23 were selected through PRISMA. These studies explore deep learning approaches for detecting diabetic neuropathy and early signs of diabetes through foot images. The most commonly used models include convolutional neural networks (CNN) and deep neural networks (DNN), which stand out for addressing challenges such as image variability and quality. However, the lack of homogeneous databases for meaningful comparisons was identified. The approaches combine CNNs with optimization algorithms and hybrid methods, achieving accuracies ranging from 81.18%, as achieved by Inception-ResNet-v2, to 99.4%, attained by EfficientNet technology. Key innovations include advanced preprocessing techniques and the integration of diverse datasets to improve generalization. Finally, recommendations are proposed to optimize these models, such as developing homogeneous and standardized databases, implementing modern architectures like EfficientNet and Inception-ResNet-v2, and exploring hybrid approaches that integrate RGB, thermal, and spectroscopic images. These measures aim to enhance diagnostic capabilities and overcome current limitations, facilitating their clinical application.

Keywords-- Deep learning; diabetic foot; diabetes; early detection; foot images.

Modelos de Deep Learning para la detección temprana y eficaz de diabetes mediante imágenes de los pies: Revisión Sistemática

Derick Andy Bonilla Regalo, Bachelor's student¹; Javier Benjhamy De la Cruz Sanchez, Bachelor's student²

Lourdes Milagrito Alegría La Rosa de Benavides, Magister³

^{1,3}Universidad Tecnológica del Perú, Perú, U20213095@utp.edu.pe, c11071@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, U20220253@utp.edu.pe

Resumen— Esta Revisión Sistemática de Literatura (RSL), realizada bajo la metodología PRISMA, tiene como objetivo identificar los modelos de inteligencia artificial recientemente propuestos para la identificación temprana de pacientes con diabetes mediante imágenes de los pies. Se analizan los problemas que estos modelos intentan resolver, las técnicas de Deep Learning (DL) utilizadas y las métricas de desempeño aplicadas. Además, se examinan los resultados obtenidos y se destacan las innovaciones en comparación con los métodos clásicos. De 237 artículos identificados en SCOPUS aplicando la metodología PICO, se seleccionaron 23 utilizando PRISMA. Estos estudios exploran el aprendizaje profundo para la detección de neuropatía diabética y signos tempranos de diabetes mediante imágenes de los pies. Los modelos más utilizados incluyen redes neuronales convolucionales (CNN) y profundas (DNN), que destacan por abordar desafíos como la variabilidad y calidad de las imágenes. Sin embargo, se identificó la falta de bases de datos homogéneas para comparaciones significativas. Los enfoques combinan CNN con algoritmos de optimización y métodos híbridos, logrando eficacias que oscilan entre el 81.18% como lo tiene Inception-ResNet-v2 hasta 99.4% que obtuvo la tecnología EfficientNet. Las principales innovaciones incluyen preprocesamiento avanzado e integración de datasets diversos para mejorar la generalización. Finalmente, se proponen recomendaciones para optimizar estos modelos, como desarrollar bases de datos homogéneas y estandarizadas, implementar arquitecturas modernas como EfficientNet e Inception-ResNet-v2, y explorar enfoques híbridos que integren imágenes RGB, térmicas y espectroscópicas. Estas medidas buscan enriquecer la capacidad diagnóstica y superar las limitaciones actuales, facilitando su aplicación clínica.

Palabras clave—Deep learning; pie diabético; diabetes; detección temprana; análisis de imágenes médicas; redes neuronales convolucionales; imágenes de los pies.

I. INTRODUCCIÓN

Durante los últimos años, la aplicación de Deep Learning (DL) ha tenido un gran impacto debido a los múltiples beneficios que se pueden obtener con su aplicación en diferentes sectores como en el campo de la salud, comercio, finanzas, entre otros, ya que tiene la capacidad de resolver problemas complejos en áreas como reconocimiento de imágenes y procesamiento de lenguaje. No obstante, esta RSL se centrará en el campo de la medicina, específicamente en la detección temprana de diabetes en pacientes. El DL se basa en un modelo computacional que utiliza múltiples capas de procesamiento para aprender representaciones de datos de

forma automática, para lograr esto se transforma la información de entrada a través de diferentes niveles de abstracción mediante módulos simples, pero no lineales, logrando así aprenderse funciones complejas [1]. Este avance ha influido positivamente en el campo de la medicina ya que se puede aplicar para la detección de diabetes, una de las enfermedades con más casos en el mundo; dicha enfermedad llega afectar principalmente a la parte inferior del cuerpo humano, provocando Ulceras de Pie Diabético (UPD). La UPD es uno de los efectos más frecuentes causadas por la diabetes mellitus, este puede llegar a provocar infecciones que podrían terminar en amputaciones de las piernas, una intervención temprana puede ayudar a prevenir las ulceraciones y también las amputaciones [2].

En la actualidad la diabetes se ha convertido en una de las enfermedades que tienen mayor impacto en las personas, ya que no solo perjudica su salud sino también su economía debido al alto costo de su tratamiento. La Federación Internacional de Diabetes estimó que, en 2021, el número total de individuos afectados por esta enfermedad (con edades comprendidas entre 20 y 79 años) fue de 537 millones de casos. Y se espera que esta cifra se incremente significativamente para el 2030 (643 millones de casos) y para el 2045 (783 millones de casos) [3]. Teniendo en cuenta este tipo de enfermedad, se han creado varios programas y aplicaciones de DL para tener un mejor enfoque en el análisis de las imágenes. Por ello, los métodos de segmentación de imágenes médicas basados en redes neuronales convolucionales (CNN) se han estudiado y aplicado ampliamente. UNet es la CNN clásica en el campo de la segmentación de imágenes médicas, con ello se propusieron otras estructuras de red basadas en esta, con una capacidad mejorada de extracción de características. Las CNN pueden lograr un alto rendimiento con un tiempo de inferencia corto, lo que facilita significativamente las aplicaciones prácticas, pero este depende de la cantidad y calidad de los datos de entrenamiento [4]. Respecto al desarrollo de herramientas tecnológicas para el diagnóstico y monitoreo del pie diabético, se desarrolló DFUCare, una plataforma basada en DL que integra múltiples capacidades para la detección, análisis y seguimiento de UPD. Este sistema trata de optimizar la precisión diagnóstica y el monitoreo clínico continuo mediante el uso de redes neuronales profundas, ofreciendo una solución integral que supera las limitaciones de enfoques anteriores, como la captura no automatizada de imágenes [5]. Sin

embargo, la implementación de elementos operacionales DL permite realizar una detección temprana de estas anomalías y se presenta como una estrategia innovadora para abordar problemas recurrentes en el campo de la medicina. Para ello, se examina las características físicas del pie, los tres métodos principales de evaluación son: El análisis de la neuropatía del pie, la circulación vascular y la presión tobillo-plantar, lo que resulta en la presentación del UPD. La detección temprana y la planificación de la atención multidisciplinaria son enfoques claves para minimizar las complicaciones del pie diabético y el tiempo de hospitalización. Una evaluación completa de los biomarcadores y la información del paciente permitiría planes de tratamiento más organizados y personalizados [6].

La necesidad de proporcionar un estudio sobre la detección temprana de estas anomalías y la implementación de elementos de operaciones de DL se presentan como estrategias innovadoras a problemas que siempre se encuentran en el área de la medicina. Las aplicaciones basadas en Inteligencia Artificial (IA) son una herramienta crucial para ayudar a los profesionales médicos con exceso de trabajo y promover mejores prácticas. Estos automatizan procedimientos repetitivos, al ofrecer ayuda para tomar decisiones en el lugar de atención, con detecciones rápidas y definitivas de cambios negativos en el curso de la curación de heridas. Diversos estudios han explorado el uso de técnicas avanzadas de DL para la detección y análisis de UPD. Estas investigaciones destacan la efectividad de modelos que integran estrategias de clasificación, segmentación y localización, mejorando significativamente la precisión diagnóstica y el monitoreo clínico de estas lesiones [7]. Por otro lado, la amplia utilización de la tecnología de la información en la práctica sanitaria conduce a la recopilación de cantidades masivas de datos, que contienen información valiosa a la espera de ser explotada. Estos “grandes datos” tienen el potencial de informar decisiones sobre la trayectoria de salud de los pacientes y el manejo de enfermedades crónicas [8]. Al respecto, una revisión reciente analiza el uso de CNN y arquitecturas derivadas como GoogLeNet, U-Net y Mask R-CNN, destacando su desempeño en tareas como la clasificación de imágenes médicas, la segmentación semántica y la localización de lesiones relacionadas con UPD con altos niveles de precisión y rendimiento [1].

El objetivo de este documento es identificar y analizar la eficacia de los modelos y tecnologías de machine learning aplicado a los síntomas de diabetes que se presentan en los pies, a través de una visión exhaustiva y organizada de soluciones relacionadas con la predicción de esta enfermedad; las que se encuentran disponibles en la literatura científica, razón por la cual, se hace necesario la elaboración de esta RSL.

La RSL presenta la siguiente estructura. La sección II. Metodología, muestra la aplicación de PICO, describiendo el procedimiento desde la formulación de la pregunta de investigación planteada hasta las operaciones que conducen a la selección del material discutido en el documento. La sección III. Resultados, presenta y organiza la información obtenida luego del análisis de los artículos encontrados. Seguidamente, en la sección IV. Discusión, se analiza detalladamente el

rendimiento de los modelos estudiados, destacando la efectividad de las redes neuronales convolucionales (CNN) y las arquitecturas modernas. Además, se evalúan técnicas de regularización como el aumento de datos, la segmentación multimodal y el uso de imágenes térmicas, que mejoran la capacidad diagnóstica. Finalmente, en la sección V. se exponen las conclusiones del estudio, donde se sintetizan los principales hallazgos, señalando tanto los avances logrados como las limitaciones observadas en esta RSL, como la carencia de bases de datos uniformes y métricas comparables. Además, se proponen líneas futuras de investigación, enfatizando la necesidad de explorar nuevas arquitecturas y garantizar una mayor estandarización en los datos para mejorar la aplicabilidad de los modelos en entornos clínicos.

II. METODOLOGÍA

A. Estrategia de búsqueda

En el presente trabajo se realizó una investigación enfocada en el uso del deep learning en el ámbito médico, específicamente para el diagnóstico temprano de complicaciones de la diabetes mediante el análisis de imágenes de los pies. Para ello se utilizó la estrategia PICO (Problema, Intervención, Comparativa, Resultado) la cual proporciona una estructura para poder entender y desglosar elementos de esta estrategia. Finalmente, todo este análisis conforma la pregunta de investigación: ¿Qué modelos de deep learning se utilizan para analizar imágenes de los pies, detectando de manera temprana y eficaz la diabetes?

TABLA I. COMPONENTES DE LA ESTRATEGIA PICO

Acrónimo	Componente	Descripción
P	Problema	¿Qué modelos de machine learning se han utilizado para predecir la diabetes en personas a partir de imágenes de los pies?
I	Intervención	¿Qué algoritmos de deep learning se han implementado para analizar imágenes de los pies con el fin de predecir la diabetes?
O	Resultado	¿Qué porcentaje de eficacia han alcanzado los modelos de deep learning en la predicción de diabetes utilizando imágenes de los pies?
C	Contexto	¿Qué tipos de imágenes de pies se utilizan en los estudios que aplican deep learning para detectar complicaciones relacionadas con la diabetes?

TABLA II. TÉRMINOS DE BÚSQUEDA

Factor	Termino de búsqueda	Sinónimos
Problema	Diabetes	Diabetes Diabetes mellitus Diabetic complications
Intervención	Deep Learning	Deep learning CNN Transfer learning
Resultado	Efficiency	Prediction Diagnosis Precision Accuracy AUC
Contexto	Foot images	Foot Infrared images Foot health Foot nails

Tras obtener los resultados iniciales, se procedió a construir las ecuaciones utilizando los términos clave, aplicando operadores booleanos como “OR” y “AND” para establecer relaciones entre las palabras clave. Este enfoque permitió ampliar o restringir el alcance de la búsqueda, como se muestra en la siguiente tabla, con base en la terminología previamente identificada para cada palabra clave.

TABLA III. SINTAXIS ECUACIÓN POR PIOC

Factor	Termino de búsqueda	Palabras clave (inglés)
Problema	Diabetes	"diabetes" OR "diabetic foot" OR "diabetes mellitus" OR "Neuropathic diabetic foot ulcer"
Intervención	Deep Learning	"deep learning" OR "CNN" OR "transfer learning" OR "convolutional neural networks"
Resultado	Efficiency	"prediction" OR "diagnosis" OR "precision" OR "accuracy" OR "AUC"
Contexto	Foot images	"foot images" OR "infrared images" OR "foot health" OR "foot nails"

La búsqueda se realizó en la base de datos de Scopus, en donde se puede encontrar diferentes artículos y revisiones sobre el tema de la detección de diabetes mediante imágenes de los pies mediante el uso de aprendizaje profundo. Para ello, se usó la siguiente ecuación de búsqueda:

(ALL ("deep learning" OR "CNN" OR "transfer learning" OR "convolutional neural networks") AND ALL ("diabetes" OR "diabetic foot" OR "diabetes mellitus" OR "Neuropathic diabetic foot ulcer") AND ALL ("foot images" OR "infrared images" OR "foot health" OR "foot nails") AND ALL (

"prediction" OR "diagnosis" OR "precision" OR "accuracy" OR "AUC"))

La ecuación de búsqueda se diseñó para cubrir los aspectos clave de la detección de diabetes mediante imágenes de los pies, utilizando términos relacionados con el aprendizaje profundo, la diabetes y las imágenes médicas. Al combinar operadores booleanos, se aseguró que los resultados abarcaran artículos relevantes sobre el uso de tecnologías avanzadas en la identificación, análisis y diagnóstico de úlceras del pie diabético.

B. Criterios de inclusión y exclusión

Para poder asegurar que los artículos que se seleccionaran fueran relevantes se utilizó los criterios de inclusión y exclusión, de este modo, esta estrategia permite seleccionar únicamente los artículos relevantes y específicos al tema de investigación, considerando los componentes del marco PICO.

TABLA IV. CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Criterios de inclusión	Criterios de exclusión
CI1: Los estudios deben abordar la detección de diabetes a través de imágenes del pie.	CE1: Estudios que se desarrollan únicamente con simulaciones o sin aplicación de deep learning.
CI2: Los estudios deben aplicar o describir modelos de deep learning para el análisis de imágenes del pie.	CE2: Tipo de publicación NO corresponde a artículo original (no se incluyen conference papers, tesis, libros de texto, o material no indexado).
CI3: Los estudios incluidos deben reportar resultados estadísticos de la aplicación de los métodos que se usan.	CE3: Publicaciones en idiomas diferentes al inglés o español.
CI4: Los estudios se han desarrollado en pacientes reales, con imágenes obtenidas en entornos clínicos o de investigación médica.	CE4: Documentos publicados antes a 2020.

C. Proceso de selección de estudio

En la ecuación de búsqueda realizada se obtuvo 237 documentos sin aplicar ningún tipo de criterio o filtros, posteriormente a esto se aplicó una lectura al contenido de estos, específicamente al título y el abstract, excluyendo consigo 31 documentos, ya que estos no trataban de la diabetes o no estaban alineados a nuestro tema a desarrollar, quedando así 206 documentos. De acuerdo con esto, se procedió a aplicar los criterios de exclusión, donde se pudo excluir 67 documentos, empezando por CE1 (Simulaciones o sin aplicación de aprendizaje profundo) en donde se eliminó 9 documentos, en el CE2 (Publicaciones que no corresponden a artículo original) se eliminaron 45 artículos, para el CE3 (idiomas diferentes al inglés o español) se eliminaron 3 artículos, y finalmente para el CE4 (publicados antes de 2020) se eliminaron 10 artículos, una vez aplicado todos los criterios se obtuvo 139 documentos. A partir de los documentos que se obtuvieron, se aplicó los criterios de inclusión analizando el contenido de estos documentos, donde se eliminaron en el CI1 (no abordan la detección de diabetes a través de imágenes del pie) 86 documentos, en el CI2 (no aplican o describen modelos

de aprendizaje profundo) se eliminó 9 documentos, se eliminaron 12 documentos en el CI3 (no reportan resultados estadísticos) y finalmente 9 documentos en el CI4 (no se desarrollaron en pacientes reales o no utilizan imágenes de entornos clínicos).

Después del proceso descrito se puede afirmar que aplicar una eliminación preliminar basada en el título y abstract los cuales no abordan o hablan del tema permitió tener una reducción significativa de documentos para poder comenzar a aplicar los criterios debido a que se pudo analizar con profundidad y seleccionar los más adecuados para la investigación. Este paso fue fundamental debido a que se pudo eliminar una gran cantidad de documentos los cuales no iban relacionados y no iban a aportar información relevante. Posterior a ello para validar todos los documentos, se aplicó los criterios de inclusión y exclusión, los cuales ya estaban definidos previamente, con la aplicación de estos se pudo asegurar que todos los documentos estén lo más alineado posible y sean adecuados para que respondan a la pregunta de investigación, gracias a ello, se pudo encontrar los artículos más pertinentes para la RSL.

III. RESULTADOS

Esta sección incluye los resultados obtenidos del proceso de revisión de los artículos seleccionados, se presenta tanto el análisis bibliométrico como los hallazgos derivados del estudio de los artículos, enfocados en modelos de DL para la detección temprana y eficaz de diabetes mediante imágenes de los pies. Para estructurar y analizar la información, se utilizaron herramientas de extracción basadas en preguntas y subpreguntas diseñadas específicamente para abordar cada componente de PIOC, asegurando que los datos recolectados fueran pertinentes a la pregunta de revisión. A continuación, se detalla cómo se relacionan estas subpreguntas con los objetivos planteados en esta RSL.

TABLA V. PREGUNTAS DEL FORMULARIO DE EXTRACCIÓN

Pregunta de revisión	
¿Qué modelos de DL se utilizan para analizar imágenes de los pies, detectando de manera temprana y eficaz la diabetes?	
Subpreguntas de revisión	Preguntas de extracción
P: ¿Qué modelos de machine learning se han utilizado para predecir la diabetes en personas a partir de imágenes de los pies?	¿Cuáles son los modelos de machine learning más comunes utilizados para la predicción de diabetes a partir de imágenes de los pies?
	¿Qué tipo de problemas específicos se abordan al utilizar machine learning para la detección de diabetes?
	¿Cómo se define la diabetes?
I: ¿Qué algoritmos de deep learning se han implementado para analizar imágenes de los pies con el fin de predecir la diabetes?	¿Cuáles son los algoritmos de deep learning más utilizados para analizar imágenes de los pies en la predicción de diabetes?
	¿Qué arquitecturas de redes neuronales se han implementado en estos estudios?
	¿Qué métodos de preprocesamiento y normalización se aplican a las imágenes antes del entrenamiento?
O: ¿Qué porcentaje de eficacia han alcanzado los modelos de deep learning en la predicción de diabetes utilizando imágenes de los pies?	¿Qué porcentaje de eficacia han alcanzado los modelos de deep learning en la predicción de diabetes utilizando imágenes de los pies?
	¿Cómo se compara el rendimiento de estos modelos con otros métodos utilizados en el estudio?
	¿Qué resultados se han obtenido de la validación cruzada o pruebas en datos independientes?

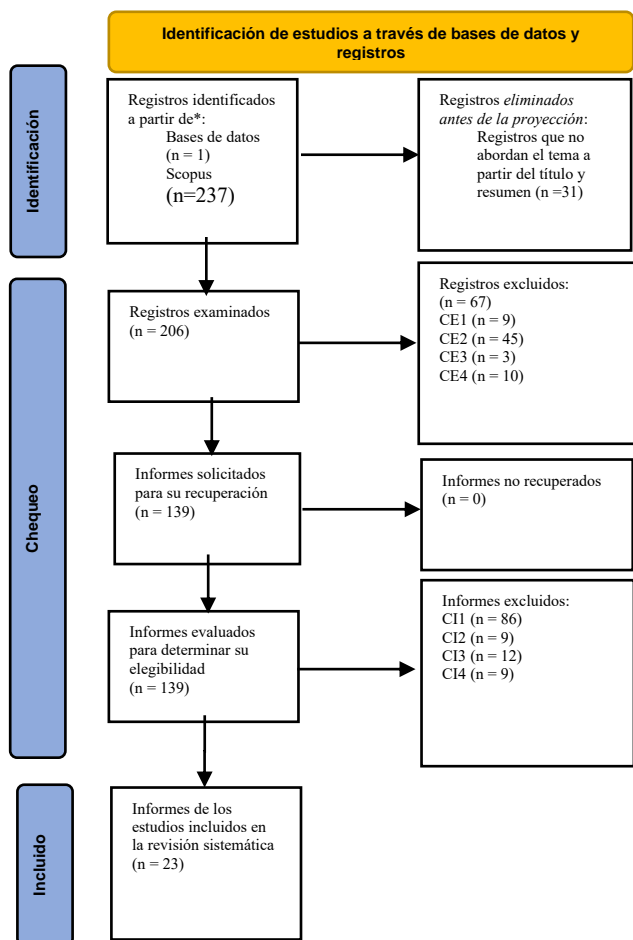


Fig. 1. Diagrama de flujo PRISMA

	¿Qué limitaciones en la precisión se han identificado, y cuáles son las áreas de mejora recomendadas?
C: ¿Qué tipos de imágenes de pies se utilizan en los estudios que aplican deep learning para detectar complicaciones relacionadas con la diabetes?	¿Qué tipos de imágenes de pies se utilizan en los estudios que aplican deep learning para detectar complicaciones relacionadas con la diabetes?
	¿Qué características específicas tienen las imágenes analizadas en los estudios?
	¿Qué procesamiento se realiza sobre las imágenes antes de su análisis?

El uso de VOSviewer para el mapeo científico ofrece la posibilidad de identificar y visualizar las estructuras de conocimiento que subyacen en áreas específicas de investigación. Esta herramienta, ampliamente aceptada en la comunidad académica de investigación, permite la creación de mapas basados en datos de coocurrencia, generando representaciones gráficas de las conexiones entre términos clave. En este análisis, se empleó VOSviewer para explorar y representar visualmente las relaciones terminológicas en el ámbito de la detección temprana de complicaciones del pie diabético mediante técnicas de deep learning, facilitando la identificación de temas centrales y sus vínculos interrelacionados. Asimismo, se utilizó Bibliometrix para complementar el análisis con mapas de relaciones y redes temáticas.

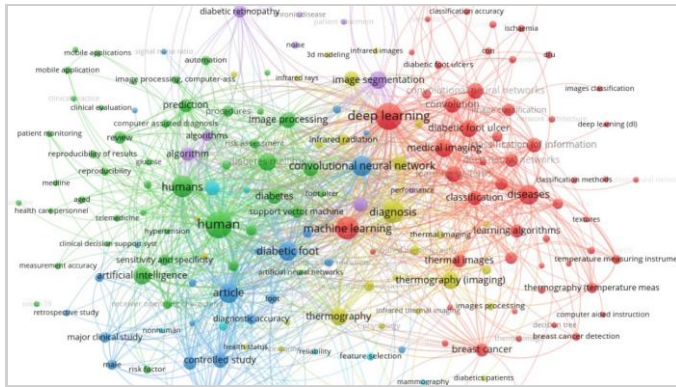


Fig. 2. Mapa de Coocurrencia de Términos en Investigación sobre Pie Diabético y Deep Learning.

En el panorama actual de la investigación sobre el pie diabético, se distinguen tres áreas fundamentales que se entrelazan de manera sinérgica mostrado en la figura 2. Por un lado, encontramos un primer grupo (rojo) centrado en la inteligencia artificial y sus aplicaciones, donde las redes neuronales y el aprendizaje profundo emergen como herramientas prometedoras para el procesamiento de datos médicos. En estrecha relación con este, el segundo grupo (azul) profundiza específicamente en el "deep learning" y las redes neuronales convolucionales (CNN), tecnologías que están

revolucionando la clasificación y análisis de imágenes médicas al permitir la identificación de patrones que escapan a los métodos tradicionales. Estas innovaciones están demostrando ser particularmente valiosas en la segmentación de imágenes y la detección automatizada de lesiones relacionadas con el pie diabético.

En cuanto al tercer grupo (verde), este se enfoca en las aplicaciones clínicas prácticas, destacando especialmente la termografía como técnica no invasiva para la detección temprana de anomalías en el flujo sanguíneo y temperaturas superficiales. Lo verdaderamente fascinante es observar cómo estos tres grupos se interconectan a través de conceptos clave como "infrared imaging", "classification methods" y "medical thermography", evidenciando una convergencia armoniosa entre la tecnología de vanguardia y los métodos clínicos tradicionales. Esta integración no solo refleja la madurez del campo, sino que también augura un futuro prometedor donde el aprendizaje profundo y la termografía se consolidan como pilares fundamentales para mejorar el diagnóstico temprano, optimizar los tratamientos y, en última instancia, reducir significativamente las complicaciones graves asociadas al pie diabético.

El análisis bibliométrico realizado a través de Bibliometrix permitió generar un gráfico que ilustra la frecuencia acumulada de términos clave relacionados con el pie diabético, el aprendizaje profundo y otras tecnologías asociadas a lo largo del tiempo. Este gráfico, que abarca el período de 2017 a 2024, ofrece una perspectiva detallada de la evolución y el impacto creciente de estos conceptos en el ámbito de la investigación.

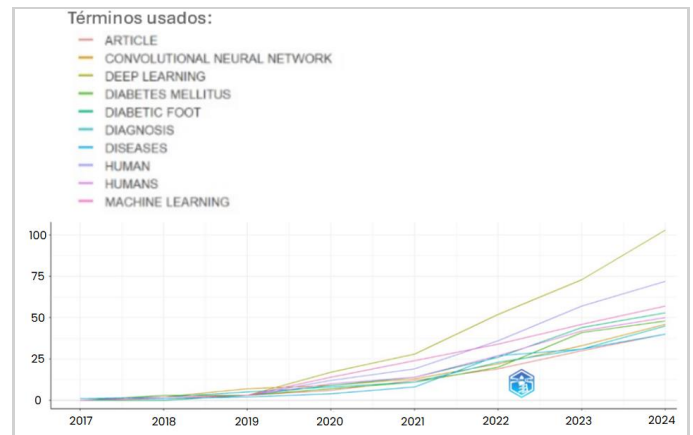


Fig. 3. Gráfico realizado con Bibliometrix de Frecuencias de palabra a largo del tiempo.

El análisis temporal mostrado en la figura 3 se revela una tendencia significativa: desde 2020 se ha registrado un marcado incremento en el uso de términos como "aprendizaje profundo", "red neuronal convolucional" y "diagnóstico", tendencia que se intensifica notablemente entre 2022 y 2024. Los datos cuantitativos respaldan esta observación, evidenciando un salto notable en las coocurrencias de términos clave: "aprendizaje profundo" se disparó de 17 menciones en 2020 a 103 en 2024, mientras que "diagnóstico" ascendió de 11

a 41 menciones en el mismo período. Paralelamente, términos como "humano" y "diabetes mellitus" han mantenido un crecimiento sostenido, lo que sugiere una convergencia cada vez más robusta entre los métodos médicos convencionales y las innovaciones en inteligencia artificial, señalando así la rápida evolución y maduración de este campo especializado.

A la vez también se usó Bibliometrix para otros análisis bibliométricos, se procedió a generar un mapa coroplético mundial que refleja la distribución geográfica de la producción científica sobre el pie diabético y las aplicaciones del deep learning. Esta visualización se complementa con una tabla de frecuencias que detalla las contribuciones por país, basadas en una muestra de 23 artículos.

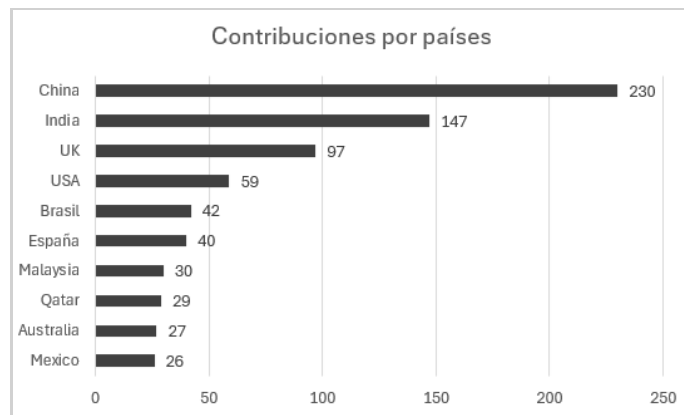


Fig. 4. Contribución Científica por País.

En cuanto a la distribución de la producción científica sobre pie diabético y tecnologías avanzadas, en la figura 4 resulta fascinante observar una clara dominancia asiática, con China liderando significativamente (230 publicaciones), seguida por India (147) y el Reino Unido (97) completando el podio de principales contribuyentes. La distribución global muestra una participación diversa pero desigual, donde países como Estados Unidos (59), Brasil (42) y España (40) mantienen una presencia intermedia, mientras que Malasia (30), Qatar (29), Australia (27) y México (26) emergen como actores prometedores en este campo. Esta distribución geográfica de la investigación refleja no solo la capacidad tecnológica de cada región, sino también su compromiso con el abordaje de la diabetes mediante herramientas de inteligencia artificial, destacando especialmente en aquellos países donde la prevalencia de la enfermedad representa un desafío significativo para la salud pública.

Finalmente, con el objetivo de observar el comportamiento temporal de la producción científica, se analizó la distribución anual de los documentos encontrados, desde el primer hasta el último registro disponible. La figura 5 presenta el número de publicaciones por año, donde se observa un incremento en el número de publicaciones a partir del año 2020, alcanzando su punto máximo en 2022, lo cual evidencia un interés creciente en la aplicación de técnicas de deep learning para la detección temprana de complicaciones diabéticas mediante imágenes podales.

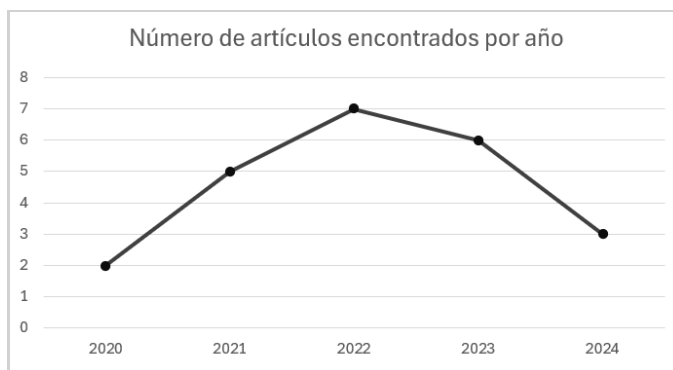


Fig. 5. Artículos encontrados por año.

A. Modelos de machine learning utilizados para predecir la diabetes.

En la Tabla VI se sintetizan los principales modelos de machine learning empleados en los artículos seleccionados para la detección temprana de diabetes mediante imágenes de los pies. Se evidencia una alta concentración en arquitecturas basadas en redes neuronales convolucionales (CNN), mientras que enfoques como U-Net, EfficientNet y Transfer Learning presentan una aplicación significativa, aunque menos dominante. Esta recopilación facilita la identificación de las tendencias actuales en la utilización de técnicas de aprendizaje profundo para el diagnóstico de complicaciones diabéticas.

TABLA VI. MODELOS DE MACHINE LEARNING UTILIZADOS

Modelo de Machine Learning	Cantidad de Artículos	% de Estudios
Redes Neuronales Convolucionales (CNN)	10	43.48%
Support Vector Machines (SVM)	6	26.09%
U-Net	4	17.39%
Inception-ResNet-v2	3	13.04%
YOLO (v3, v4, v8)	3	13.04%
EfficientNet (B0-B5)	3	13.04%
Random Forest (RF)	2	8.70%
ResNet (varias versiones)	2	8.70%
AlexNet	2	8.70%
GoogleNet	2	8.70%
Faster R-CNN	2	8.70%
Sparse Autoencoder (SSAE)	1	4.35%
Decision Tree	1	4.35%
Regresión Logística	1	4.35%
Bag of Features (BOF)	1	4.35%

B. Algoritmos de Deep learning utilizados para el análisis de imágenes de pies.

Las redes neuronales convolucionales (CNN) fueron los algoritmos más utilizados, apareciendo en 10 de los 23 artículos revisados, lo que representa un 43.48% del total. Este enfoque destaca por su capacidad para extraer características jerárquicas y clasificar imágenes de manera precisa, siendo implementado en tareas como segmentación y detección de patrones complejos [9], [11], [13], [15], [21], [22], [23], [24], [26], [27]. En segundo lugar, el modelo U-Net fue empleado en 4 artículos (17.39%), principalmente para segmentar regiones específicas en imágenes médicas [15], [23], [26], [27].

Asimismo, algoritmos avanzados como Inception-ResNet-v2, EfficientNet y YOLO se utilizaron en 3 artículos cada uno (13.04%), mostrando su versatilidad en tareas de clasificación y detección en tiempo real [15], [21], [23], [26]. Por otro lado, arquitecturas como ResNet también tuvieron una presencia destacada en 3 estudios (13.04%), mientras que AlexNet y GoogleNet se emplearon en 2 artículos cada uno (8.70%), sirviendo mayormente para la extracción de características y clasificación [15], [23], [25]. Finalmente, técnicas menos comunes como Sparse Autoencoder (SSAE) y el modelo personalizado DFTNet fueron implementadas en 1 artículo cada uno (4.35%), demostrando ser útiles en escenarios específicos [22], [28], [31].




Fig. 6. Algoritmos de Deep learning utilizados para el análisis de imágenes de pies.

C. Porcentaje de eficacia de los modelos de deep learning en la predicción de diabetes utilizando imágenes de los pies.

Los modelos de deep learning aplicados a la predicción de diabetes mediante imágenes de los pies alcanzaron porcentajes de eficacia variables según la arquitectura utilizada. Las redes neuronales convolucionales (CNN) lograron resultados entre el 64.6% y el 99.4%, mientras que U-Net, diseñado específicamente para segmentación, registró eficacias entre el 93.3% y el 98.9% [9], [11], [15], [23], [27]. Por su parte, Inception-ResNet-v2 mostró un rango de entre el 81.18% y el 99.29%, y YOLO presentó porcentajes de entre el 72.7% y el 90.3% [15], [21], [23]. Asimismo, EfficientNet, implementado en varios estudios, reportó valores entre el 96.1% y el 99.4%, destacándose por su precisión en clasificación [15], [21], [23].

En los modelos personalizados, DFTNet alcanzó un porcentaje único del 94.53%, mientras que Sparse Autoencoder (SSAE) registró un 99.29% al ser combinado con Inception-ResNet-v2 [22], [31]. Por otro lado, arquitecturas tradicionales como AlexNet y GoogleNet obtuvieron eficacias de 81.18% y 81.84%, respectivamente [15], [23], [29]. Finalmente, enfoques como Faster R-CNN presentaron eficacias entre el 83.3% y el 99%, mientras que SegNet mostró un rango de entre el 87.57% y el 93.3%, utilizados en tareas de segmentación y detección [15], [23], [27].




Fig. 7. Eficacia de los modelos de deep learning en la predicción de diabetes utilizando imágenes de los pies.

D. Tipos de técnicas de regularización en imágenes de pies utilizados en los estudios que aplican deep learning para detectar complicaciones relacionadas con la diabetes.

En la Tabla VII se exponen las principales técnicas de regularización empleadas en los estudios seleccionados que aplican deep learning para la detección temprana de complicaciones diabéticas mediante imágenes podales. Se presentan tanto el número de documentos que aplican cada estrategia como su proporción relativa respecto al total analizado, evidenciando una predominancia del aumento de datos, el uso de Dropout y la normalización de imágenes.

TABLA VII. TÉCNICAS DE REGULARIZACIÓN EN IMÁGENES DE PIES DE ESTUDIOS QUE APLICAN DEEP LEARNING.

Técnicas de Regularización en Imágenes	Cantidad de Artículos	% de Documentos Seleccionados
Aumento de datos (Data Augmentation)	15	65.22%
Dropout	9	39.13%
Normalización de imágenes	8	34.78%
Imágenes térmicas	7	30.43%
Transferencia de aprendizaje	6	26.08%
Pesos inicializados preentrenados	6	26.08%
Segmentación multimodal	4	17.39%
Filtros de derivada gaussiana	2	8.69%

Imágenes ópticas y técnicas de espectroscopía	2	8.69%
---	---	-------

IV. DISCUSIÓN Y CONCLUSIÓN

A. *Discusión*

En este estudio de revisión, las redes neuronales convolucionales (CNN) destacaron como las arquitecturas más utilizadas en la predicción de diabetes mediante imágenes de pies, presentes en el 43.48% de los estudios revisados [9], [11], [15], [21], [23]. En comparación con modelos tradicionales como AlexNet y GoogleNet, que alcanzaron eficacias de entre el 81.18% y el 81.84% [15], [23], las CNN lograron resultados significativamente más altos, llegando hasta el 99.4% en arquitecturas avanzadas como EfficientNet [15], [21], [23]. A diferencia de lo reportado en estudios previos que priorizan arquitecturas tradicionales, esta revisión evidencia una transición hacia modelos más robustos como Inception-ResNet-v2, que obtuvo eficacias de entre el 81.18% y el 99.29% [15], [21], [23]. Sin embargo, en contraste con estas arquitecturas modernas, se observó que modelos personalizados como DFTNet y Sparse Autoencoder (SSAE) lograron resultados sobresalientes de hasta el 94.53% y el 99.29%, respectivamente, optimizando tareas específicas relacionadas con la predicción de complicaciones [22], [31].

En cuanto a las técnicas de regularización, el aumento de datos se utilizó en el 65.22% de los estudios revisados, siendo la técnica más implementada para diversificar los conjuntos de datos mediante transformaciones como rotación, recorte e inversión [9], [11], [12], [15], [16], [21], [23]. En comparación con técnicas menos frecuentes como los filtros de derivada gaussiana, reportados en solo el 8.7% de los estudios [19], [24], el aumento de datos mostró una mayor capacidad para prevenir el sobreajuste. A diferencia de lo reportado en estudios que se limitan a imágenes RGB, esta revisión identificó un uso significativo de imágenes térmicas en el 30.43% de los estudios [11], [14], [22], [30], [31], lo que permitió analizar patrones de temperatura y microcirculación útiles para identificar alteraciones metabólicas relacionadas con la diabetes. En contraste con las imágenes térmicas, las imágenes ópticas y técnicas de espectroscopía, presentes en solo el 8.7% de los estudios, aportaron enfoques adicionales para resaltar patrones sutiles en las imágenes [14], [28].

A diferencia de lo reportado en investigaciones que no integran múltiples fuentes de datos, esta revisión destacó la implementación de segmentación multimodal, presente en el 17.39% de los estudios, que combinó información de imágenes RGB, térmicas y de profundidad para mejorar la capacidad diagnóstica [15], [22], [26], [27]. También se encontró que técnicas avanzadas como U-Net, diseñadas específicamente para segmentación, lograron eficacias que oscilaron entre el 93.3% y el 98.9%, superando en precisión a modelos más generalistas como AlexNet y GoogleNet [15], [23], [27]. En contraste con estos enfoques, arquitecturas modernas como EfficientNet mostraron un equilibrio entre precisión y eficiencia computacional, destacándose por su capacidad de alcanzar eficacias de hasta el 99.4% [15], [21], [23].

Finalmente, en contraste con estudios previos que priorizan la estandarización de conjuntos de datos, esta revisión identificó una falta de uniformidad en las métricas de evaluación utilizadas en los estudios analizados. Esto representa una limitación significativa que dificulta la comparación directa de los resultados. A pesar de ello, los hallazgos de esta revisión confirman que el avance en la predicción de diabetes mediante imágenes de los pies depende en gran medida de la integración efectiva de arquitecturas modernas como EfficientNet y Inception-ResNet-v2 con técnicas de regularización como el aumento de datos y la segmentación multimodal. Futuras investigaciones deberían centrarse en desarrollar bases de datos homogéneas y explorar arquitecturas emergentes, como los transformadores y el aprendizaje auto-supervisado, para abordar las limitaciones actuales y mejorar la generalización de los modelos en entornos clínicos diversos.

A. *Conclusión*

Esta revisión sistemática analizó la aplicación de modelos de deep learning y machine learning para la detección de diabetes y complicaciones asociadas mediante imágenes de los pies, respondiendo al objetivo de explorar las técnicas más efectivas y su impacto en el diagnóstico clínico. Los hallazgos identificaron que las redes neuronales convolucionales (CNN) son las arquitecturas más utilizadas debido a su capacidad para extraer características jerárquicas y abordar tareas de clasificación y segmentación con altos niveles de precisión, alcanzando eficacias de hasta el 99.4% en arquitecturas modernas como EfficientNet e Inception-ResNet-v2. Asimismo, se destacó el uso de modelos personalizados como DFTNet y Sparse Autoencoder (SSAE), que lograron eficacias superiores al 94%, evidenciando su utilidad en tareas específicas.

En cuanto a las técnicas de preprocesamiento y regularización, el aumento de datos fue la más implementada, presente en el 65.22% de los estudios, mientras que el uso de imágenes térmicas y segmentación multimodal proporcionó enfoques complementarios al análisis basado en imágenes RGB, permitiendo una mejor identificación de patrones relacionados con la diabetes. Estas estrategias, aunque menos frecuentes, destacaron por su capacidad de enriquecer la diversidad y calidad de los datos.

La principal contribución de esta revisión radica en sintetizar y comparar las técnicas y modelos existentes, ofreciendo una visión clara de los avances en la predicción de diabetes mediante imágenes médicas, lo que aporta información valiosa para investigadores y profesionales del área. Sin embargo, esta revisión presenta limitaciones, como la falta de estandarización en los conjuntos de datos y métricas utilizadas en los estudios revisados, lo que dificulta la comparación directa de resultados entre investigaciones. Para futuros trabajos, se recomienda explorar el desarrollo de técnicas avanzadas como el aprendizaje auto-supervisado y los transformadores, que podrían mejorar la capacidad de los modelos para generalizar en diferentes contextos clínicos. También sería importante establecer estándares claros para los conjuntos de datos, asegurando consistencia en la calidad de las

imágenes, el etiquetado y las condiciones de captura. Además, investigar enfoques híbridos que integren imágenes RGB, térmicas y espectroscópicas podría ampliar las capacidades diagnósticas y abordar limitaciones actuales, contribuyendo a un diagnóstico más preciso y eficiente de las complicaciones relacionadas con la diabetes.

REFERENCIAS

- [1] J. Zhang, Y. Qiu, L. Peng, Q. Zhou, Z. Wang, y M. Qi, “A comprehensive review of methods based on deep learning for diabetes-related foot ulcers”, *Frontiers In Endocrinology*, vol. 13, ago. 2022, doi: 10.3389/fendo.2022.945020.
- [2] N. C. Evangeline y S. Srinivasan, “Deep neural net for identification of neuropathic foot in subjects with type 2 diabetes mellitus using plantar foot thermographic images”, *Biomedical Signal Processing And Control*, vol. 96, p. 106509, jun. 2024, doi: 10.1016/j.bspc.2024.106509.
- [3] D. Spoladore, M. Tosi, y E. C. Lorenzini, “Ontology-based decision support systems for diabetes nutrition therapy: A systematic literature review”, *Artificial Intelligence In Medicine*, vol. 151, p. 102859, mar. 2024, doi: 10.1016/j.artmed.2024.102859.
- [4] J. Zhou *et al.*, “Improving deep learning based segmentation of scars using multi-view images”, *Biomedical Signal Processing And Control*, vol. 94, p. 106254, mar. 2024, doi: 10.1016/j.bspc.2024.106254.
- [5] V. Sendilraj *et al.*, “DFUCare: deep learning platform for diabetic foot ulcer detection, analysis, and monitoring”, *Frontiers In Endocrinology*, vol. 15, sep. 2024, doi: 10.3389/fendo.2024.1386613.
- [6] R. Basiri *et al.*, “Protocol for metadata and image collection at diabetic foot ulcer clinics: enabling research in wound analytics and deep learning”, *BioMedical Engineering OnLine*, vol. 23, n.o 1, ene. 2024, doi: 10.1186/s12938-024-01210-6.
- [7] M. H. Yap *et al.*, “Deep learning in diabetic foot ulcers detection: A comprehensive evaluation”, *Computers In Biology And Medicine*, vol. 135, p. 104596, jun. 2021, doi: 10.1016/j.combiomed.2021.104596.
- [8] K. Chen, F. Abtahi, J.-J. Carrero, C. Fernandez-Llatas, y F. Seoane, “Process mining and data mining applications in the domain of chronic diseases: A systematic review”, *Artificial Intelligence In Medicine*, vol. 144, p. 102645, ago. 2023, doi: 10.1016/j.artmed.2023.102645.
- [9] T. Weatherall *et al.*, “The impact of machine learning on the prediction of diabetic foot ulcers – A systematic review,” 2024, Tissue Viability Society. doi: 10.1016/j.jtv.2024.07.004.
- [10] L. Yang and Z. Zhou, “Effects of nutrition intervention on the rehabilitation level and quality of life of patients with diabetes foot: Image observation based on image recognition technology,” *Prev Med (Baltim)*, vol. 173, Aug. 2023, doi: 10.1016/j.ypmed.2023.107578.
- [11] G. Verma, “Leveraging smart image processing techniques for early detection of foot ulcers using a deep learning network,” *Pol J Radiol*, vol. 89, pp. e368–e377, 2024, doi: 10.5114/pjr/189412.
- [12] K. M. Mousa, F. A. Mousa, H. S. Mohamed, and M. M. Elsayy, “Prediction of Foot Ulcers Using Artificial Intelligence for Diabetic Patients at Cairo University Hospital, Egypt,” *SAGE Open Nurs*, vol. 9, Jan. 2023, doi: 10.1177/23779608231185873.
- [13] P. N. Thotad, G. R. Bharamagoudar, and B. S. Anami, “Diabetic foot ulcer detection using deep learning approaches,” *Sensors International*, vol. 4, Jan. 2023, doi: 10.1016/j.sintl.2022.100210.
- [14] Z. Wang *et al.*, “Smart diabetic foot ulcer scoring system,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-62076-1.
- [15] B. Cassidy *et al.*, “Artificial intelligence for automated detection of diabetic foot ulcers: A real-world proof-of-concept clinical evaluation,” *Diabetes Res Clin Pract*, vol. 205, Nov. 2023, doi: 10.1016/j.diabres.2023.110951.
- [16] M. Hida *et al.*, “Development of Hallux Valgus Classification Using Digital Foot Images with Machine Learning,” *Life*, vol. 13, no. 5, May 2023, doi: 10.3390/life13051146.
- [17] A. Alqahtani *et al.*, “Empowering Foot Health: Harnessing the Adaptive Weighted Sub-Gradient Convolutional Neural Network for Diabetic Foot Ulcer Classification,” *Diagnostics*, vol. 13, no. 17, Sep. 2023, doi: 10.3390/diagnostics13172831.
- [18] R. Sarmun *et al.*, “Diabetic Foot Ulcer Detection: Combining Deep Learning Models for Improved Localization,” *Cognit Comput*, vol. 16, no. 3, pp. 1413–1431, May 2024, doi: 10.1007/s12559-024-10267-3.
- [19] L. Carlos Padierna, L. Fabián Amador-Medina, B. Olivia Murillo-Ortiz, and C. Villaseñor-Mora, “Classification method of peripheral arterial disease in patients with type 2 diabetes mellitus by infrared thermography and machine learning,” *Infrared Phys Technol*, vol. 111, Dec. 2020, doi: 10.1016/j.infrared.2020.103531.
- [20] A. Heras-Tang, D. Valdes-Santiago, A. Leon-Mecias, M. L. B. Diaz-Romañach, and J. A. Mesejo-Chiong, “Diabetic foot ulcer segmentation using logistic regression, DBSCAN clustering and morphological operators,” *Electronic Letters on Computer Vision and Image Analysis*, vol. 21, no. 2, pp. 23–39, 2022, doi: 10.5565/REV/ELCVIA.1413.
- [21] S. Madhava Prabhu and S. Verma, “Automated classification of the diabetic foot using comprehensive encoding and feature transform techniques,” *International Journal of Computing and Digital Systems*, vol. 9, no. 4, pp. 747–753, Jul. 2020, doi: 10.12785/IJCDS/090421.
- [22] S. Ellahham, “Artificial Intelligence: The Future for Diabetes Care,” Aug. 01, 2020, Elsevier Inc. doi: 10.1016/j.amjmed.2020.03.033.
- [23] N. Arteaga-Marrero, A. Hernández, E. Villa, S. González-Pérez, C. Luque, and J. Ruiz-Alzola, “Segmentation approaches for diabetic foot disorders,” *Sensors (Switzerland)*, vol. 21, no. 3, pp. 1–16, Feb. 2021, doi: 10.3390/s21030934.
- [24] K. S. Chan and Z. J. Lo, “Wound assessment, imaging and monitoring systems in diabetic foot ulcers: A systematic review,” *Int Wound J*, vol. 17, no. 6, pp. 1909–1923, Dec. 2020, doi: 10.1111/iwj.13481.
- [25] N. Christy Evangeline, S. Srinivasan, and E. Suresh, “Application of non-contact thermography as a screening modality for Diabetic Foot Syndrome – A real time cross sectional research outcome,” *Biomed Signal Process Control*, vol. 79, Jan. 2023, doi: 10.1016/j.bspc.2022.104054.
- [26] M. Goyal, N. D. Reeves, S. Rajbhandari, N. Ahmad, C. Wang, and M. H. Yap, “Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques,” *Comput Biol Med*, vol. 117, Feb. 2020, doi: 10.1016/j.combiomed.2020.103616.
- [27] I. Cruz-Vega, D. Hernandez-Contreras, H. Peregrina-Barreto, J. de J. Rangel-Magdaleno, and J. M. Ramirez-Cortes, “Deep learning classification for diabetic foot thermograms,” *Sensors (Switzerland)*, vol. 20, no. 6, Mar. 2020, doi: 10.3390/s20061762.
- [28] I. Muller *et al.*, “Combining thermal imaging and machine learning to noninvasively characterize palm perfusion during local blood pressure changes,” *Biomed Signal Process Control*, vol. 92, Jun. 2024, doi: 10.1016/j.bspc.2024.106109.
- [29] S. Nagaraju *et al.*, “Automated Diabetic Foot Ulcer Detection and Classification Using Deep Learning,” *IEEE Access*, vol. 11, pp. 127578–127588, 2023, doi: 10.1109/ACCESS.2023.3332292.
- [30] B. Monroy *et al.*, “Automated chronic wounds medical assessment and tracking framework based on deep learning,” *Comput Biol Med*, vol. 165, Oct. 2023, doi: 10.1016/j.combiomed.2023.107335.
- [31] M. H. Alshayegi, S. ChandraBhasi Sindhu, and S. Abed, “Early detection of diabetic foot ulcers from thermal images using the bag of features technique,” *Biomed Signal Process Control*, vol. 79, Jan. 2023, doi: 10.1016/j.bspc.2022.104143.