

## Técnicas de inteligencia artificial para detección temprana de retinopatía diabética Artificial Intelligence Techniques for Early Detection of Diabetic Retinopathy

M. de J. Sánchez-Villa <sup>a,\*</sup>, E. O. Martínez-Jiménez <sup>a</sup>

<sup>a</sup>Ciencias y Tecnologías Biomédicas, Instituto Nacional de Astrofísica Óptica y Electrónica, 72840, Santa María Tonanzintla, Puebla, México.

### Resumen

Este artículo ofrece una revisión de estudios recientes que exploran el uso de inteligencia artificial (IA) en el diagnóstico temprano de la retinopatía diabética (RD). Se destacan técnicas avanzadas como el transfer learning (TL), redes neuronales convolucionales (CNN) y deep learning (DL) como herramientas prometedoras para mejorar la detección temprana de RD. Dada la naturaleza crónica y progresiva de la RD, que afecta gravemente la salud ocular y la calidad de vida de los pacientes, su detección temprana es crucial. A pesar de los avances en el tratamiento, la RD sigue siendo una de las principales causas de ceguera en adultos en edad laboral a nivel mundial. Este enfoque en IA busca prevenir la progresión de la enfermedad y mitigar sus efectos adversos.

*Palabras Clave:* Inteligencia artificial, Aprendizaje profundo, Retinopatía diabética, Detección temprana.

### Abstract

This article provides a review of recent studies exploring the use of artificial intelligence (AI) in early diagnosis of diabetic retinopathy (DR). Advanced techniques such as transfer learning (TL), convolutional neural networks (CNN), and deep learning (DL) are highlighted as promising tools to enhance early detection of DR. Given the chronic and progressive nature of DR, which severely affects ocular health and patients' quality of life, early detection is crucial. Despite advances in treatment, DR remains one of the leading causes of blindness in working-age adults worldwide. This AI-focused approach aims to prevent disease progression and mitigate its adverse effects.

*Keywords:* Artificial intelligence, Deep learning, Diabetic retinopathy, Early detection.

### 1. Introducción

La retinopatía diabética es una complicación crónica y progresiva de la diabetes mellitus que afecta significativamente la salud ocular y la calidad de vida de los pacientes. Se caracteriza por cambios en los vasos sanguíneos de la retina que pueden conducir a la pérdida de visión si no se diagnostica y trata adecuadamente. A pesar de los avances en los métodos de diagnóstico y tratamiento, la retinopatía diabética sigue siendo una de las principales causas de ceguera en adultos en edad laboral en todo el mundo.

El diagnóstico temprano de la retinopatía diabética es fundamental para prevenir la progresión de la enfermedad y mitigar sus efectos adversos. Sin embargo, existen desafíos significativos en la detección temprana y eficaz de esta complicación en pacientes con diabetes. Los métodos de diagnóstico tradicionales, como la fotografía del fondo de ojo, pueden ser limitados en su capacidad para identificar cambios sutiles en la retina

en etapas tempranas de la enfermedad, es por esto que la implementación de nuevas tecnologías de imagenología, como el análisis computarizado de imágenes, son importantes, ya que abre nuevas posibilidades para mejorar la detección temprana de la retinopatía diabética. Sin embargo, aún se requiere una evaluación exhaustiva de la efectividad y la precisión de estos métodos en comparación con los enfoques convencionales.

En este contexto, surge la necesidad de investigar y evaluar críticamente los diagnósticos recientes para mejorar la detección temprana de la retinopatía diabética. Es fundamental comprender la eficacia, la sensibilidad y la especificidad de las nuevas tecnologías de diagnóstico.

Con estas consideraciones en mente, en este artículo analizamos cuáles son las herramientas de IA recientes más prometedoras para mejorar la detección temprana de la retinopatía diabética. Se espera que el uso de tecnologías de diagnóstico más avanzadas, como la inteligencia artificial aplicada al análisis

\*Autor para correspondencia: [miriamdejesussanchezvilla@gmail.com](mailto:miriamdejesussanchezvilla@gmail.com)

**Correo electrónico:** [miriamdejesussanchezvilla@gmail.com](mailto:miriamdejesussanchezvilla@gmail.com) (Miriam de Jesús Sánchez-Villa), [omar\\_jim0305@outlook.com](mailto:omar_jim0305@outlook.com) (Edgar Omar Martínez-Jiménez).

**Historial del manuscrito:** recibido el 25/04/2024, última versión-revisada recibida el 02/07/2024, aceptado el 29/08/2024, en línea (postprint) desde el 23/09/2024, publicado el 05/07/2025. **DOI:** <https://doi.org/10.29057/icbi.v13i25.12848>



sis de imágenes de retina, mejore significativamente la detección temprana de la retinopatía diabética.

## 2. Retinopatía diabética

La clasificación de la severidad de la retinopatía diabética (RD) desarrollada por el Global Diabetic Retinopathy Project Group (GDRPG) en 2003 y respaldada por la Academia Americana de Oftalmología, (Aliseda y Berástegui, 2008), ha establecido un estándar de trabajo en la práctica clínica. Esta clasificación proporciona una estructura fácilmente memorizable, realizada e interpretable por oftalmólogos y otros profesionales de la salud que tratan a pacientes diabéticos.

Esta clasificación se utiliza para evaluar el grado de severidad de la retinopatía diabética, lo que ayuda en la toma de decisiones clínicas y en el diseño de planes de tratamiento adecuados para cada paciente. Al seguir esta clasificación, los profesionales de la salud pueden estandarizar la evaluación de la RD y garantizar una atención de calidad para los pacientes diabéticos.

La clasificación actual de la retinopatía diabética examina el edema macular y la retinopatía diabética del polo posterior por separado, lo que resulta en su tratamiento en secciones distintas de esta monografía. La gravedad de la retinopatía diabética se evalúa mediante la simple observación del fondo de ojo y se divide en cinco niveles claramente establecidos.

### 2.1. Sin retinopatía aparente.

No se observan lesiones características al examen oftalmoscópico.

### 2.2. Retinopatía no proliferante leve

La primera alteración observable oftalmoscópicamente en la retinopatía diabética son los microaneurismas retinianos. Estos microaneurismas son dilataciones de la pared de los capilares y se visualizan como pequeños puntos rojos con bordes muy definidos.

### 2.3. Retinopatía diabética no proliferante moderada

Se observan hemorragias retinianas en un número inferior a 20 en los cuatro cuadrantes. Además, pueden presentarse exudados duros o lipídicos, así como exudados blandos o algodinosos. Además de esto, puede haber dilataciones venosas en forma de rosario en un solo cuadrante, caracterizadas por zonas bien definidas de dilatación con áreas de estrechez venosa, similares a cuentas en un rosario como se ve en la Figura 1.



Figura 1: Retinopatía diabética no proliferante moderada, con microaneurismas, microhemorragias y exudados.

### 2.4. Retinopatía diabética no proliferante severa

Pueden presentarse muchas hemorragias dentro del ojo, más de 20 en cada una de las cuatro cuadrantes, venas agrandadas en forma de rosario en al menos dos áreas, o anomalías microvasculares intrarretinianas, que son difíciles de ver directamente ver Figura 2. Si se observan todas estas alteraciones, hay un alto riesgo de que la enfermedad empeore. Por ejemplo, hay un 50,2 % de probabilidad de que empeore en un año, y un 14,6 % de que empeore de manera grave. Si se cumplen todos estos criterios, el riesgo total de que empeore es del 45 % en un año.



Figura 2: Retinopatía diabética severa. Se pueden ver microhemorragias e intrarretinianas en los cuadrantes. Igualmente se ven exudados duros y microaneurismas.

### 2.5. Retinopatía diabética proliferante

Esto abarca cualquier crecimiento anormal de vasos sanguíneos en la retina o el disco óptico, así como hemorragias extensas en el gel vítreo o debajo de la retina ver Figura 3. Esto incluye desde formas leves o moderadas de crecimiento de nuevos vasos hasta formas más graves y avanzadas con crecimiento fibrovascular y desprendimiento de la retina. En este nivel de gravedad, se requerirá tratamiento con láser para controlar la evolución, especialmente en casos de crecimiento de vasos sanguíneos en el disco óptico o hemorragia vítreo. En formas avanzadas, puede ser necesaria una vitrectomía junto con láser intraocular.

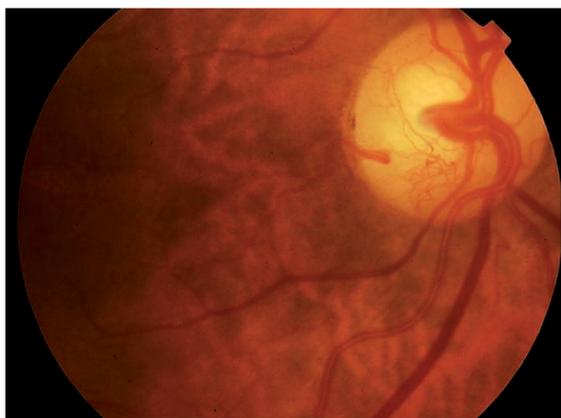


Figura 3: Retinopatía proliferante donde se observan claramente los neovasos papilares.

### 3. Inteligencia artificial

En su libro “Inteligencia Artificial: 100 aspectos esenciales sobre nuestro futuro”, Lasse Rouhiainen describe la inteligencia artificial como la capacidad de las computadoras para llevar a cabo tareas que generalmente son realizadas por la inteligencia humana. Además, se entiende por inteligencia artificial la capacidad de las máquinas para emular el pensamiento humano y realizar tareas que requieren aprendizaje, razonamiento y adaptación. También se define como el campo de estudio que busca crear sistemas capaces de realizar tareas que, para el ser humano, requieren inteligencia, como el reconocimiento de patrones, la toma de decisiones y el procesamiento del lenguaje natural.

En el contexto médico, la inteligencia artificial está revolucionando la detección y diagnóstico de enfermedades, como la retinopatía diabética. La inteligencia artificial abarca un amplio espectro de técnicas y metodologías, estas tecnologías permiten a los sistemas de inteligencia artificial aprender de grandes conjuntos de datos de imágenes de la retina, identificando patrones y anomalías que podrían ser indicativos de retinopatía diabética.

#### 3.1. Deep Learning

El deep learning se refiere al uso de redes neuronales con múltiples capas, pero no se trata solo de apilar capas. Las redes neuronales profundas (DNN) y las redes neuronales convolucionales (CNN) utilizan capas de convolución y reducción de datos (pooling) que permiten captar características complejas y jerárquicas de las imágenes.

En este artículo, se analizaron distintos trabajos con distintas arquitecturas de deep learning, incluyendo VGG16, ResNet50, InceptionV3 y EfficientNet, debido a su eficacia demostrada en tareas de clasificación de imágenes médicas. Estas arquitecturas no solo dependen del número de capas, sino también de cómo están estructuradas y conectadas. Por ejemplo, ResNet50 utiliza bloques residuales que permiten entrenar redes más profundas sin problemas de desvanecimiento del gradiente. InceptionV3 utiliza módulos Inception que permiten manejar diferentes escalas de características simultáneamente, mejorando la precisión.

Es crucial entender que simplemente añadir más capas no garantiza un mejor desempeño. El diseño de la arquitectura de la red, la selección de hiperparámetros y la calidad del conjunto de datos son factores determinantes en el éxito de los modelos de deep learning.

#### 3.2. Transfer Learning

El transfer learning es una técnica que permite utilizar el conocimiento adquirido durante el entrenamiento de un modelo en una tarea específica para mejorar el rendimiento en una tarea relacionada pero distinta. En lugar de entrenar un modelo desde cero con un nuevo conjunto de datos, el transfer learning utiliza un modelo preentrenado, generalmente en una tarea con una gran cantidad de datos, y ajusta o “transfiere” este conocimiento a una tarea nueva y específica con un conjunto de datos más pequeño. Para la detección de retinopatía diabética, el transfer learning ha demostrado ser una técnica eficaz en el mejoramiento del rendimiento de los sistemas de inteligencia artificial, especialmente cuando se dispone de conjuntos de datos limitados o desequilibrados.

Algunos de los modelos de transfer learning más efectivos incluyen ImageNet y ResNet101. Estos modelos, preentrenados en grandes conjuntos de datos como ImageNet, han sido ajustados para la tarea específica de detección de retinopatía diabética. La elección del modelo específico depende de factores como la disponibilidad de datos, los recursos computacionales y los objetivos específicos del estudio.

### 4. Análisis de artículos

En esta sección, presentamos un análisis integrado de una serie de estudios relevantes que emplean diferentes técnicas de IA para la detección temprana de RD. La recopilación está estructurada en función de las técnicas de IA utilizadas, permitiendo una comparación y comprensión sistemática de los enfoques más prometedores en este campo. Al categorizar y sintetizar la información clave de múltiples fuentes según las técnicas de IA, nuestro objetivo es ofrecer a los profesionales de la salud y a los investigadores una visión detallada y actualizada de las estrategias más efectivas y las áreas de innovación en la detección temprana de RD.

El artículo “Multi-Level severity classification for diabetic retinopathy based on hybrid optimization enabled deep learning”, publicado en 2023 por S. Zulaikha (Beevi, 2023), emplea la técnica de SqueezeNet junto con una Red Neuronal Convolucional Profunda (DCNN) en dos etapas para desarrollar una clasificación innovadora de la severidad de la retinopatía diabética (RD). Inicialmente, SqueezeNet se utiliza para clasificar las imágenes de fondo de ojo como normales o anormales en cuanto a RD. En este proceso, se aplica la Estrategia de Guerra de Optimización Fraccional (FrWSO), que fusiona la Optimización de Estrategia de Guerra (WSO) con el Cálculo Fraccional (FC), para ajustar SqueezeNet. Luego, el nivel de gravedad de las imágenes anormales se establece utilizando una Red Neuronal Convolucional Profunda, DCNN, en una segunda fase de análisis. Además, se introduce un algoritmo llamado Optimización Fraccional de Batalla Real (FrWRO), que combina la Optimización de Batalla Real (BRO) con FrWSO, para calibrar

la DCNN. Los resultados indican que el enfoque propuesto logra una precisión del 0.911, una sensibilidad del 0.898 y una especificidad del 0.913, mostrando un rendimiento destacado.

En su artículo de 2020, “Hyperparameter Tuning Deep Learning for Diabetic Retinopathy Fundus Image Classification” (Shankar *et al.*, 2020b), K. Shankar introduce un innovador modelo automatizado llamado Ajuste de Hiperparámetros Inception-v4 (HPTI-v4) diseñado para la detección y clasificación de retinopatía diabética (RD) utilizando imágenes de fondo de ojo a color. Durante la fase de preprocesamiento, se emplea el modelo de ecualización adaptativa del histograma limitado por contraste (CLAHE) para mejorar el contraste de la imagen del fondo de ojo. A continuación, se lleva a cabo la segmentación de la imagen preprocesada utilizando un enfoque basado en histogramas. El modelo HPTI-v4 se utiliza para identificar las características clave de la imagen segmentada, que luego se clasifica mediante un perceptrón multicapa (MLP). Se realizan experimentos en el conjunto de datos de RD MESSIDOR para validar la efectividad del enfoque HPTI-v4, y los resultados demuestran de manera significativa la eficacia superior del modelo HPTI-v4 en comparación con otros métodos. El modelo HPTI-v4 presentado mostró resultados extraordinarios con una precisión máxima, sensibilidad y especificidad del 99.49 %, 98.83 % y 99.68 % respectivamente. Por lo tanto, el modelo HPTI-v4 puede ser utilizado como una herramienta de diagnóstico automatizado para la clasificación de imágenes de RD.

El artículo de K. Shankar, “Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model” (Shankar *et al.*, 2020a), introduce un modelo de aprendizaje profundo llamado modelo SDL diseñado para la detección y clasificación automática de imágenes de fondo de ojo relacionadas con la RD. El objetivo principal de esta investigación es lograr una clasificación precisa de estas imágenes con una alta tasa de detección. En la fase de preprocesamiento, se eliminó el ruido que afectaba los bordes de las imágenes. Posteriormente, se utilizó una técnica de segmentación basada en histogramas para identificar y extraer las áreas relevantes de la imagen. El modelo SDL se implementó luego para categorizar las imágenes de fondo de ojo de RD en distintas categorías. Para comprobar la eficacia del modelo SDL en la detección de RD, se empleó el conjunto de datos estándar MESSIDOR. Los resultados experimentales demostraron que el método propuesto logró una clasificación sobresaliente, con una precisión máxima del 99.28 %, una sensibilidad del 98.54 % y una especificidad del 99.38 %.

En el artículo “Automatic Detection of Diabetic Hypertensive Retinopathy in Fundus Images Using Transfer Learning” publicado por (Nagpal *et al.*, 2023), el enfoque de transfer learning se ha utilizado en la clasificación de la retinopatía diabética con resultados alentadores. En su estudio, se ha propuesto un método automatizado para diagnosticar y clasificar la retinopatía diabética y la coriorretinopatía serosa central. Este método consta de tres etapas: preprocesamiento, segmentación y extracción de características. El preprocesamiento incluye técnicas para reducir el ruido en las imágenes retinianas, como el filtrado A-CLAHE, DNCNN y Wiener. Luego, se segmentan los vasos sanguíneos utilizando el umbral de OTSU y la morfología matemática. La extracción y clasificación de características se realiza mediante modelos de aprendizaje por transferencia, es-

pecíficamente utilizando la arquitectura modificada de ResNet 101. La evaluación del rendimiento muestra una mejora en la calidad de las imágenes en comparación con estudios previos, con una precisión de clasificación del 98,72 % en un conjunto de datos de más de 6000 imágenes de retinas.

El estudio de Niloy Sikder publicado en 2021, “Severity Classification of Diabetic Retinopathy Using an Ensemble Learning Algorithm through Analyzing Retinal Images” (Sikder *et al.*, 2021), presenta un enfoque innovador para el diagnóstico de la RD. Utiliza la intensidad de nivel de gris y características de textura extraídas de imágenes de retina mediante una técnica de aprendizaje conjunto apoyada en árboles de decisión. Este trabajo se centra principalmente en el conjunto de datos APTOS 2019 BD de la Sociedad de Tele-Oftalmología del Asia Pacífico para analizar y preparar las imágenes. Se calcularon histogramas y GLCM de cada imagen para optimizar el contenido y adaptarlo mejor a las aplicaciones de aprendizaje automático. Se optimizaron los hiperparámetros del algoritmo XGBoost para maximizar el rendimiento del conjunto de características desarrollado. Además, se empleó un algoritmo genético (GA) para destacar las características más relevantes en la clasificación, mostrando que esta selección no afecta significativamente el rendimiento del método. El método logra una precisión media de clasificación del 94.20 % con el conjunto total de características y del 93.70 % con las características específicamente seleccionadas.

El artículo (Qomariah *et al.*, 2019) propone un método de aprendizaje profundo para la extracción de características y clasificación utilizando una máquina de vectores de soporte (SVM). Utilizamos las características de alto nivel de la última capa completamente conectada, basadas en el aprendizaje por transferencia de una Red Neuronal Convolutiva (CNN), como características de entrada para la clasificación utilizando la máquina de vectores de soporte (SVM). Este método reduce el tiempo de computación requerido por el proceso de clasificación utilizando CNN con ajuste fino. El método propuesto se prueba utilizando 77 y 70 imágenes retinianas de la base de datos Messidor de la base 12 y la base 13, respectivamente. A partir de los resultados de los experimentos, los valores de precisión más altos son del 95.83 % y del 95.24 % para la base 12 y la base 13, respectivamente.

En el artículo (Afrin y Shill, 2019), se presenta un sistema sólido que identifica anomalías retinianas, como vasos sanguíneos, microaneurismas y exudados, en imágenes de la retina y categoriza automáticamente las etapas de la RD. Primero, emplean técnicas de procesamiento de imágenes para detectar los vasos sanguíneos, microaneurismas y exudados. Luego, extraen características retinianas, como el área de los vasos sanguíneos, el número de microaneurismas, el área de los exudados, el contraste y la homogeneidad, de las imágenes procesadas. Estas características se introducen en un clasificador difuso basado en conocimientos para determinar las etapas de normalidad, NPDR leve, NPDR moderado, NPDR grave y PDR. Se utilizan un total de 400 imágenes de fondo de ojo de las bases de datos STARE, DIARETDB0 y DIARETDB1, y el clasificador difuso logra clasificar las imágenes con una precisión de hasta el 95.63 %. En el artículo (Butt *et al.*, 2019), se presenta un sistema basado en una Red Neuronal Convolutiva (CNN) de múltiples canales para identificar la RD en imágenes de fondo

de ojo. Este sistema se evalúa utilizando un conjunto de datos de RD que incluye 35,126 imágenes facilitadas por EyePACS. Los resultados experimentales muestran que el modelo alcanza una precisión del 97.08 %, superando las cifras obtenidas por otros métodos en investigaciones recientes. En el artículo (Momeni Pour *et al.*, 2020), se presenta un modelo innovador para el monitoreo de la retinopatía diabética que utiliza el método de Ecuación del Histograma Adaptativo Limitado por Contraste para mejorar y uniformizar la calidad de las imágenes como etapa de preprocesamiento. Posteriormente, se emplea la arquitectura EfficientNet-B5 para la clasificación. La particularidad de esta red radica en la uniformidad al escalar todas las dimensiones de la misma. El modelo se entrena una sola vez con una mezcla de dos conjuntos de datos, Messidor-2 e IDRiD, y se evalúa en el conjunto de datos Messidor. Se logra mejorar el área bajo la curva (AUC) de 0.936, que representa el valor más alto en todos los estudios recientes, a 0.945. Asimismo, para una evaluación adicional del desempeño del modelo, se lo entrena con una combinación de Messidor-2 y Messidor, y se evalúa con el conjunto de datos IDRiD, obteniendo un AUC mejorado de 0.796, el valor más alto en todos los estudios recientes, a 0.932. En comparación con otras investigaciones, el modelo propuesto muestra una mejora en el AUC.

En el artículo "Retinal vessel extraction using Lattice Neural Networks with dendritic processing" publicado por (Vega *et al.*, 2015), presenta los avances logrados mediante el uso de una red neuronal de celosía con procesamiento dendrítico (LNNDP). Se describieron los resultados obtenidos utilizando varias métricas y los comparan con métodos ampliamente conocidos, como las Máquinas de Soporte Vectorial (SVM) y los Perceptrones Multicapa (MLP). La propuesta demuestra resultados superiores a otros enfoques. Una ventaja adicional es que, a diferencia de otras herramientas, LNNDP no requiere la configuración de parámetros y ajusta automáticamente su estructura para abordar un problema específico. La metodología propuesta consta de cuatro etapas: (1) Preprocesamiento, (2) Extracción de características, (3) Clasificación y (4) Postprocesamiento. Para reducir la dimensionalidad del vector de características, utilizamos la carta de control de Hotelling T2, lo que redujo de 7 a 5 dimensiones en este estudio. Los experimentos se llevaron a cabo utilizando imágenes de las bases de datos DRIVE y STARE. Los resultados muestran que, en promedio, LNNDP supera en puntuación F1 a las implementaciones de SVM y MLP. Se observa una mejora similar en las métricas MCC y precisión.

Tabla 1: Arquitecturas usadas.

Artículo	Arquitectura	Técnica usada
(Vega <i>et al.</i> , 2015)	LNN	LNNDP
(Butt <i>et al.</i> , 2019)	CNN MCC	DL
(Afrin y Shill, 2019)	-	Lógica difusa
(Qomariah <i>et al.</i> , 2019)	SVM	DL, TL
(Momeni Pour <i>et al.</i> , 2020)	EfficientNet-B5	CLAHE
(Shankar <i>et al.</i> , 2020b)	Inception-v4	DL
(Shankar <i>et al.</i> , 2020a)	SDL	DL
(Sikder <i>et al.</i> , 2021)	XGBoost	EL
(Beevi, 2023)	SqueezeNet	DL
(Nagpal <i>et al.</i> , 2023)	ResNet 101	TL

## 5. Discusión y resultados

La detección temprana y precisa de la retinopatía diabética (RD) es fundamental para prevenir la pérdida de visión en pacientes con diabetes. En este contexto, varios estudios han explorado el potencial de las técnicas de Inteligencia Artificial (IA) para mejorar la detección y clasificación de la RD a partir de imágenes de fondo de ojo.

Uno de los enfoques más destacados es el presentado por S. Zulaikha en 2023 (Beevi, 2023), que emplea una combinación de SqueezeNet y una Red Neuronal Convolutiva Profunda (DCNN). Utilizando la Estrategia de Guerra de Optimización Fraccional (FrWSO) y la Optimización Fraccional de Batalla Real (FrWRO), este método logra una precisión del 0.911, una sensibilidad del 0.898 y una especificidad del 0.913. Estos resultados destacan la eficacia de las técnicas de optimización avanzada en la mejora del rendimiento de los modelos de detección de RD.

Por otro lado, K. Shankar en 2020 (Shankar *et al.*, 2020b) introdujo un modelo automatizado llamado Ajuste de Hiperparámetros Inception-v4 (HPTI-v4). Este modelo utiliza el modelo Inception-v4 para la clasificación de imágenes de fondo de ojo con una precisión máxima, sensibilidad y especificidad impresionantes del 99.49 %, 98.83 % y 99.68 %, respectivamente. Además, en otro estudio del mismo autor (Shankar *et al.*, 2020a), se presenta el modelo SDL, que emplea técnicas de segmentación basada en histogramas y logra una precisión máxima del 99.28 %, sensibilidad del 98.54 % y especificidad del 99.38 %.

El aprendizaje por transferencia también ha mostrado ser una estrategia eficaz para la detección de RD. En el artículo de (Nagpal *et al.*, 2023), se utilizó la arquitectura modificada de ResNet 101, logrando una precisión de clasificación del 98,72 % en un conjunto de datos de más de 6000 imágenes de retinas.

En cuanto a los enfoques que combinan aprendizaje profundo con algoritmos de clasificación más simples, el estudio de (Qomariah *et al.*, 2019) propone un método que utiliza características de alto nivel de una CNN con una máquina de vectores de soporte (SVM). Este enfoque reduce el tiempo de computación y alcanza una precisión del 95.83 % y 95.24 % en diferentes conjuntos de datos.

Además, varios estudios han empleado enfoques innovadores para mejorar la clasificación de la RD. Por ejemplo, el estudio de Niloy Sikder (Sikder *et al.*, 2021) utiliza árboles de decisión y XGBoost para la clasificación con una precisión media del 94.20 %. Otros estudios como el de (Afrin y Shill, 2019) emplean técnicas de procesamiento de imágenes para detectar características específicas de la retina, como vasos sanguíneos, microaneurismas y exudados, y logran una precisión de hasta el 95.63 %.

La calidad de las imágenes y el preprocesamiento también juegan un papel crucial en la precisión de los modelos. Estrategias como la ecualización del histograma y el ajuste de hiperparámetros, como se ve en (Shankar *et al.*, 2020b), (Momeni Pour *et al.*, 2020) y (Nagpal *et al.*, 2023), han demostrado ser fundamentales para mejorar la calidad de las imágenes y, por ende, la precisión del modelo.

Finalmente, es importante destacar las innovaciones en las arquitecturas de redes neuronales utilizadas para la detección de

RD. La introducción de nuevas arquitecturas como SqueezeNet, Inception-v4 y EfficientNet-B5, ha demostrado ser efectiva para mejorar la detección de RD, como se observa en (Beevi, 2023), (Shankar *et al.*, 2020b) y (Momeni Pour *et al.*, 2020).

Los resultados obtenidos pueden verse de forma más clara en la tablas 2 y 3.

Tabla 2: Comparación de resultados.

Artículo	Precisión	Sensibilidad
(Vega <i>et al.</i> , 2015)	0.9189	0.8189
(Butt <i>et al.</i> , 2019)	0.9708	-
(Afrin y Shill, 2019)	0.9563	-
(Qomariah <i>et al.</i> , 2019)	0.9583	-
(Momeni Pour <i>et al.</i> , 2020)	-	-
(Shankar <i>et al.</i> , 2020b)	0.9949	0.9883
(Shankar <i>et al.</i> , 2020a)	0.9928	0.9854
(Sikder <i>et al.</i> , 2021)	0.9370	-
(Beevi, 2023)	0.911	0.898
(Nagpal <i>et al.</i> , 2023)	0.9872	-

Tabla 3: Comparación de resultados.

Artículo	Especificidad	AUC
(Vega <i>et al.</i> , 2015)	0.9269	-
(Butt <i>et al.</i> , 2019)	-	-
(Afrin y Shill, 2019)	-	-
(Qomariah <i>et al.</i> , 2019)	-	-
(Momeni Pour <i>et al.</i> , 2020)	-	0.932
(Shankar <i>et al.</i> , 2020b)	0.9968	-
(Shankar <i>et al.</i> , 2020a)	0.9938	-
(Sikder <i>et al.</i> , 2021)	-	-
(Beevi, 2023)	0.913	-
(Nagpal <i>et al.</i> , 2023)	-	-

## Conclusiones

Los modelos basados en aprendizaje profundo, como HPTI-v4 y SDL, muestran un rendimiento sobresaliente en la detección y clasificación de RD, con precisión superior al 99 % en algunos casos. La utilización de técnicas de optimización híbridas y ajuste de hiperparámetros, como en el modelo de Zulaikha, puede resultar efectiva para mejorar la precisión de los modelos. El enfoque de aprendizaje conjunto de Sikder ofrece resultados prometedores, aunque con una precisión ligeramente inferior en comparación con los modelos basados en aprendizaje profundo

Los avances recientes en el uso de técnicas de IA para la detección temprana de la retinopatía diabética muestran un progreso significativo. Los modelos basados en deep learning, especialmente aquellos que utilizan técnicas avanzadas de optimización y arquitecturas innovadoras, lideran en términos de precisión y eficiencia. Además, el uso de técnicas de preprocesamiento avanzado y aprendizaje por transferencia ha demostrado ser crucial para mejorar la calidad de las imágenes y la precisión de los modelos. Estos resultados prometedores abren nuevas posibilidades para el desarrollo de herramientas de diagnóstico automatizado más efectivas y precisas para la detección temprana de la retinopatía diabética.

## Referencias

- Afrin, R. y Shill, P. C. (2019). Automatic lesions detection and classification of diabetic retinopathy using fuzzy logic. *2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*, pp. 527–532.
- Aliseda, D. y Berástegui, L. (2008). Retinopatía diabética. *Anales del sistema sanitario de Navarra*, 31:23–34.
- Beevi, S. Z. (2023). Multi-level severity classification for diabetic retinopathy based on hybrid optimization enabled deep learning. *Biomedical Signal Processing and Control*, 84:104736.
- Butt, M., Latif, G., Iskandar, D., Alghazo, J., y Khan, A. (2019). Multi-channel convolutions neural network based diabetic retinopathy detection from fundus images. *Procedia Computer Science*, 163:283–291.
- Momeni Pour, A., Seyedarabi, H., Abbasi Jahromi, S. H., y Javadzadeh, A. (2020). Automatic detection and monitoring of diabetic retinopathy using efficient convolutional neural networks and contrast limited adaptive histogram equalization. *IEEE Access*, 8:136668–136673.
- Nagpal, D., Alsubaie, N., Soufiene, B. O., Alqahtani, M. S., Abbas, M., y Almohiy, H. M. (2023). Automatic detection of diabetic hypertensive retinopathy in fundus images using transfer learning. *Applied Sciences*, 13(8):4695.
- Qomariah, D. U. N., Tjandrasa, H., y Faticah, C. (2019). Classification of diabetic retinopathy and normal retinal images using cnn and svm. *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, pp. 152–157.
- Shankar, K., Sait, A. R. W., Gupta, D., Lakshmanaprabu, S. K., Khanna, A., y Pandey, H. M. (2020a). Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model. *Pattern Recognition Letters*, 133:210–216.
- Shankar, K., Zhang, Y., Liu, Y., Wu, L., y Chen, C. H. (2020b). Hyperparameter tuning deep learning for diabetic retinopathy fundus image classification. *IEEE access*, 8:118164–118173.
- Sikder, N., Masud, M., Bairagi, A. K., Arif, A. S. M., y Nahid, A. A. ans Alhumyani, H. A. (2021). Severity classification of diabetic retinopathy using an ensemble learning algorithm through analyzing retinal images. *Symmetry*, 13(4):670.
- Vega, R., Sanchez-Ante, G., Falcon-Morales, L. E., Sossa, H., y Guevara, E. (2015). Retinal vessel extraction using lattice neural networks with dendritic processing. *Computers in biology and medicine*, 58:20–30.