

# **Detección automática de la Retinopatía Diabética ¿Mito o realidad?**



**M.C. David Ferreiro Piñeiro**  
**Dr. Iván Olmos Pineda**  
**Dr. José Arturo Olvera López**  
*Benemérita Universidad  
Autónoma de Puebla (BUAP)*



**Abstract**

Diabetic Retinopathy has become a worldwide health problem affecting diabetic people of working age, generating loss of vision or permanent blindness to patients, affecting their quality of life. Clinical detection methods are time consuming and expensive, which translates into a high incidence of this disease. Contemporary technological developments can be used to carry out the diagnosis of the disease, from the use of computer vision techniques that relate the areas of pattern recognition, image processing and artificial intelligence.

**Palabras clave:** Retinopatía diabética, visión computacional, reconocimiento de patrones, inteligencia artificial

**Keywords:** Diabetic Retinopathy, computer vision, pattern recognition, artificial intelligence

**Estilos de vida y Salud Visual**

Los cambios en los estilos de vida, el consumo de bebidas azucaradas, la falta de actividad física, entre otros factores, ha provocado el aumento de las enfermedades metabólicas y dentro de ellas la Diabetes. Esta enfermedad, genera un descontrol en los niveles de azúcar en la sangre que repercute en el correcto funcionamiento de los diferentes sistemas que integran el cuerpo humano.

Uno de los sistemas comúnmente afectado es el sistema visual y dentro de este, específicamente los ojos. Los ojos son los órganos encargados de permitir la percepción del mundo que nos rodea mediante la transformación de estímulos lumínicos en impulsos electroquímicos. Los impulsos electroquímicos son generados, mediante diferentes procesos en la retina y son pro-

cesados posteriormente en el interior del cerebro.

La retina es una capa de tejido que se ubica en la parte posterior del ojo. En ella se encuentran las células fotosensibles encargadas de realizar la transformación de los estímulos lumínicos, así como la entrada del nervio óptico, y de la red de pequeños vasos sanguíneos responsables de la irrigación de estos tejidos.

La acumulación de azúcar en estos pequeños vasos genera el “goteo” o la obstrucción de la circulación sanguínea en el interior del ojo y ello se deriva en una enfermedad conocida como Retinopatía Diabética (RD). Esta enfermedad tiene un carácter progresivo que dificulta su detección oportuna y posterior tratamiento y, según la Organización Mundial de la Salud (OMS), es la principal causa de ceguera en edades laborales (International Diabetes Federation, 2018; Martínez-Murcia et al., 2021).

La detección de esta enfermedad se realiza utilizando métodos clínicos que permiten observar la retina de los pacientes en búsqueda de las lesiones características. Sin embargo, estos métodos: fondos de ojo, angiografías, ecografías y tomografías de coherencia óptica; resultan invasivos y altamente subjetivos al depender de la preparación de los especialistas, al tiempo que son costosos y demorados. Ello genera que muchas personas no sean atendidas adecuadamente y que la enfermedad continúe evolucionando, disminuyendo la calidad de vida de los pacientes.

Por estas razones la OMS ha recomendado el diseño de sistemas de detección que utilicen los adelantos tecnológicos existentes para garantizar la atención a la mayor cantidad de pacientes (World Health

Organization, 2019). En este sentido, se han desarrollado algunos métodos que utilizan el procesamiento digital de las imágenes de la retina para detectar y posteriormente clasificar el estado de avance de la enfermedad en cuestión.

Una imagen de la retina (ver Figura 1) es una fotografía del tejido que permite observar la estructura de la red vascular, el disco óptico, la mácula, entre otras estructuras (Dutta et al., 2018).



Figura 1. Imagen de la retina. Fuente (Decencièrre et al., 2014)

El análisis de estas imágenes posibilita la detección de lesiones distintivas de diferentes enfermedades, por este motivo,


resulta atractivo el desarrollo de métodos o metodologías que garanticen estos análisis de manera automática usando los avances computacionales actuales.

### **Análisis de imágenes en diagnósticos médicos**

La acelerada evolución de las técnicas de análisis de imágenes, las capacidades de cómputo y el desarrollo de repositorios públicos, ha permitido la incursión de diferentes técnicas de visión computacional y de aprendizaje de máquina en los procesos de diagnóstico de diferentes enfermedades.

La RD se diagnostica a partir de la detección de algunas lesiones en las imágenes de la retina: microaneurismas, hemorragias, exudados duros o blandos, neovascularizaciones, entre otros (Rio Torres et al., 2018). La ocurrencia de estas lesiones determina los cuatro estados de la enfermedad: leve, moderado, severo o proliferativo; en la Figura 2 se observan algunas de las lesiones especificadas anteriormente.

En las primeras etapas de la enfermedad, aunque se afecta la calidad de vida de los pacientes, no existe peligro inminente de pérdida de la visión.



A) Hemorragias

B) Anomalías vasculares

C) Exudados

Figura 2. Manifestaciones clínicas de la Retinopatía Diabética. Fuente (Decencièrre et al., 2014)

El estado proliferativo es el más grave y en él se desarrollan nuevos vasos sanguíneos defectuosos que provocan hemorragias severas e incluso desprendimientos de la retina, representando una elevada probabilidad de pérdida permanente de la visión. Estas lesiones son de difícil detección, por tal motivo resulta importante el diseño de algoritmos capaces de diagnosticar esta enfermedad de manera objetiva y con relativa simpleza.

En este sentido, se desarrollan técnicas que permitan procesar, analizar, comprender y transformar las imágenes de entrada de forma que puedan ser tratadas por sistemas de cómputo, lo que comúnmente se llama visión computacional. Se busca finalmente el diseño de sistemas de detección automática de patrones, reconocimiento u otras aplicaciones.

Las nuevas investigaciones, se enfocan en el desarrollo de algoritmos que utilizan Redes Neuronales Profundas (DNN), Redes Neuronales Convolucionales (CNN) o sistemas basados en el meta-aprendizaje, con diferentes arquitecturas.

Las DNN son sistemas que emulan el comportamiento del cerebro humano, donde se modulan las neuronas biológicas como unidades de suma interconectadas entre ellas para generar un proceso similar a las sinapsis. Cuando se trabaja con redes neuronales su “entrenamiento”, veámoslo como sinónimo de aprendizaje, se encarga de modelar las conexiones entre cada una de las neuronas o elementos, de tal manera que sean capaces de realizar asociaciones para poder identificar determinado proceso de interés.

Por otro lado, las CNN intentan emular el comportamiento jerárquico del siste-

ma visual humano. El término convolucional se refiere a la realización de la operación de convolución por parte de las capas iniciales de la red. Una convolución, en el sentido del procesamiento de imágenes, es un conjunto de operaciones o filtros que se aplican a los píxeles o elementos de la imagen.

Esta operación nos permite realizar la extracción de características cada vez más específicas desde la imagen original, por ejemplo: una primera convolución detecta bordes aislados, una segunda convolución interconecta esos bordes y así sucesivamente hasta que se logra extraer aquellas características que conforman o describen un determinado objeto de interés.

Parte del atractivo de este tipo de sistema respecta a que permite detectar las características en cualquier parte de la imagen lo que le da determinada fortaleza o invarianza respecto a la posición del objeto u objetos de interés. Como principal desventaja podemos señalar el hecho de que a medida que aumenta su profundidad, si bien teóricamente mejoraría su comportamiento, se observa que comienzan a aparecer fenómenos que dificultan su capacidad de generalización. Sucede que el sistema “aprende” características irrelevantes que describen determinado conjunto de datos, pero que resultan inadecuadas cuando se aplican a otros entornos, entre otras problemáticas que aumentan el costo computacional.

### **Enfoques automáticos de diagnóstico de la RD**

Los avances iniciales en las ramas computacionales provocaron un entusiasmo por la posibilidad de aplicación en las ciencias médicas (el diagnóstico de la RD no fue la excepción). En este sentido resulta posible

identificar dos áreas o enfoques de trabajo:

- 1 La extracción manual de características distintivas y el empleo de estrategias clásicas de clasificación (Maaten et al., 2020).
- 2 La extracción automática de características.

Actualmente existe una marcada tendencia al desarrollo dentro del segundo enfoque. Esto se debe a que el primer enfoque realiza un proceso de ingeniería de características.

La ingeniería de características es el proceso mediante el cual el ingeniero o especialista decide qué características resultan relevantes para su problema. Esto tiene tres inconvenientes: en primer lugar, se requiere de personal altamente calificado para identificar las mejores características, en segundo lugar, resulta extremadamente extenuante y demorado y, por último, pero no menos importante, tiene problemas de generalización; es decir, las características que funcionaron para un problema pueden o no funcionar para otro problema similar.

El segundo enfoque evita los problemas de generalización, pero implica mayor poder de cómputo y cantidad de datos para realizar el entrenamiento de los diferentes modelos. Actualmente estos problemas no influyen de manera significativa en el diseño de este tipo de sistemas y a partir de 2015 se observa una tendencia creciente en su desarrollo con resultados verdaderamente alentadores.

### ¿Existen imágenes disponibles?

Los enfoques basados en la extracción automática de características y el apren-

dizaje profundo requieren de muchos datos para poder “aprender”. Con ese objetivo se han desarrollado diferentes repositorios públicos con datos ya etiquetados por especialistas: “*Methods to Evaluate Segmentation and Indexing Techniques in the field of Retinal Ophthalmology (Messidor)*” (Decencière et al., 2014), “*High-Resolution Fundus Image (HRF)*” (Budai et al., 2013), “*Indian Diabetic Retinopathy Image Dataset (IDRiD)*” (Porwal et al., 2018, 2020), entre otras.

Los repositorios se orientan tanto a la detección de lesiones específicas como a la clasificación del grado de avance de la enfermedad y permiten no solo el diseño de nuevos algoritmos, sino también, la posibilidad de comparar los resultados experimentales de forma objetiva.

Estos repositorios permiten el acceso a las imágenes para los procesos de diagnóstico de la RD, no obstante, es importante considerar que: fueron conformados bajo diferentes condiciones y las imágenes capturadas con equipos de distintas características; por tanto, resulta necesario realizar procesos de preprocesamiento previos a su empleo, en el desarrollo de los sistemas de interés.

### Desarrollos recientes

Los desarrollos recientes se orientan al diseño de sistemas de diagnóstico basados en CNN; en este sentido se proponen diferentes arquitecturas que difieren en cuanto a los parámetros que describen su comportamiento: profundidad, número de filtros utilizados, tamaño de las rejillas de convolución, entre otros. Estos parámetros permiten realizar una amplia variedad de combinaciones con resultados alentadores.

Otros autores modifican redes ya establecidas y utilizan un paradigma de entrenamiento conocido como transferencia de aprendizaje. Este paradigma permite ajustar la configuración de redes previamente entrenadas en otros problemas a la problemática de interés. Es decir, con anterioridad un investigador realizó una propuesta de red para una actividad determinada, por ejemplo, la detección de perros o gatos en imágenes; durante el entrenamiento de esa red, el sistema “aprende” aquellas características de alto nivel que permiten identificar uno u otro animal. Luego, esta red puede ser extrapolada a un nuevo problema y “aprende” a adaptarse a las nuevas características distintivas de los elementos que se desee identificar.

Este esquema resulta muy atractivo en aquellos casos en los que no se dispone de suficientes imágenes o de repositorios lo suficientemente grandes como para entrenar un modelo de red desde cero, como el área de las ciencias médicas. Además, posibilita inicializar las conexiones entre los elementos de la red, en valores ya establecidos y no de forma aleatoria; en este sentido varias investigaciones han demostrado su utilidad y su influencia en el tiempo de convergencia de los algoritmos.

El entrenamiento de estos sistemas no resulta una acción trivial, y se enfrenta a muchos problemas derivados de los propios algoritmos de entrenamiento. Como resultado existe un área de investigación encargada del desarrollo de sistemas híbridos, es decir: la extracción de características se realiza utilizando sistemas convolucionales, mientras que los procesos de clasificación emplean otras técnicas conocidas. Este enfoque tiene como ventaja la relativa sencillez del

proceso de clasificación, así como el menor costo computacional al tiempo que prescinde de las labores de ingeniería de características que dificultan las labores de generalización de los resultados.

Otros enfoques vigentes realizan operaciones morfológicas sobre las imágenes y los procesos de clasificación emplean técnicas estadísticas, para lo cual segmentan las lesiones específicas y además consideran aspectos relacionados con la propia morfología de la red vascular, el disco óptico u otros elementos dentro de la retina. Estos enfoques, aunque válidos, resultan laboriosos en los procesos de extracción de características y dependen del apoyo de especialistas calificados que permitan identificar claramente los aspectos de interés en las imágenes.

En este sentido, es importante considerar que las métricas de éxito empleadas con mayor frecuencia son la especificidad, la sensibilidad y la exactitud de los algoritmos; pues permiten considerar qué tan eficientes resultan los sistemas para detectar efectivamente la presencia de la enfermedad o en caso contrario su ausencia. Estos valores deben compararse con el desempeño de los especialistas humanos como paso previo a la validación de los modelos.

### **Futuro del diagnóstico automático**

Resulta notorio la incursión de los adelantos tecnológicos en los procesos de diagnósticos médicos, sin embargo, al ser un área sensible es preciso considerar los factores éticos. En este sentido, si bien es cierto que un sistema computacional puede clasificar o diagnosticar la enfermedad en cuestión objetivamente, es importante establecer mecanismos que nos permitan comprender bajo qué reglas o qué aspectos

considera el sistema para dar su solución.

Este hecho resulta trascendente a medida que los sistemas basados en redes neuronales aumentan su complejidad y profundidad. El aumento de las capas ocultas de los modelos genera un efecto conocido como “caja negra” en el que no se conoce, a ciencia cierta, qué características se están considerando en la toma de decisiones y ello resulta determinante en el área médica.

El desarrollo de modelos computacionales basados en la inteligencia artificial, la visión computacional o el procesamiento digital de imágenes, resulta un área atractiva y sumamente importante, y se deben diseñar mecanismos o estrategias que permitan interpretar o entender los resultados obtenidos que, en última instancia, posibiliten a los especialistas auditar los modelos desarrollados.

### Conclusiones

El desarrollo de diferentes técnicas de visión computacional, así como de la inteligencia artificial, abre un área de oportunidad importante en el tratamiento de determinadas afecciones de la salud. Se realizó un esbozo de los principales enfoques de trabajo desarrollados para abordar las labores de diagnóstico de la Retinopatía Diabética empleando estas técnicas. Constituye esta, un área de investigación atractiva y en constante evolución como resultado del aumento de la capacidad computacional.

Sin embargo, debido a la sensibilidad del área de aplicación de los conocimientos, resulta importante que los nuevos modelos o sistemas desarrollados puedan interpretarse con claridad, de forma tal que se puedan auditar rápidamente por los especialistas como mecanismo para garantizar la validez de las propuestas y de dar certe-

za de las investigaciones en el área.

Sin dudas, el futuro de la oftalmología y de las ciencias de forma general, pasa por el diseño de sistemas automáticos que simplifiquen los procesos que actualmente realizan los especialistas; para garantizar la atención al tiempo que se disminuyan los requerimientos de costo o tiempo.

### Referencias

Budai, A., Bock, R., Maier, A., Hornegger, J., y Michelson, G. Robust Vessel Segmentation in Fundus Images. *Int. J. Biomed. Imaging*, 2013, pp. 1–11, 2013. <https://doi.org/10.1155/2013/154860>

Decencièere, E., Zhang, X., Cazuguel, G., Lay, B., Cochener, B., Trone, C., Gain, P., Ordóñez-Varela, J. R., Massin, P., Erginay, A., Charton, B., y Klein, J. C. Feedback on a publicly distributed image database: The Messidor database. *Image Anal. Stereol.* <https://doi.org/10.5566/ias.1155>

Dutta, S., Manideep, B. C. S., Basha, S. M., Caytiles, R. D., y Iyengar, N. C. S. N. Classification of Diabetic Retinopathy Images by Using Deep Learning Models. *Int. J. Grid Distrib. Comput.*, 11[1], pp. 99–106, 2018. <https://doi.org/10.14257/ijgcd.2018.11.1.09>

International Diabetes Federation. *International Diabetes Federations response to the 3rd UN HLM on NCDs political declaration.*

Martínez-Murcia, F. J., Ortiz, A., Ramírez, J., Górriz, J. M., y Cruz, R. Deep residual transfer learning for automatic diagnosis and grading of diabetic retinopathy. *Neurocomputing*, 452, pp. 424–434, 2021. <https://doi.org/10.1016/j.neucom.2020.04.148>

- Mateen, M., Wen, J., Hassan, M., Nasrullah, N., Sun, S., y Hayat, S. Automatic Detection of Diabetic Retinopathy: A Review on Datasets, Methods and Evaluation Metrics. *IEEE Access*, 8, pp. 48784–48811, 2020. <https://doi.org/10.1109/ACCESS.2020.2980055>
- Porwal, P., Pachade, S., Kamble, R., Kokare, M., Deshmukh, G., Sahasrabuddhe, V., y Meriaudeau, F. Indian Diabetic Retinopathy Image Dataset (IDRiD). *IEEE Dataport*. <https://doi.org/10.21227/H25W98>
- Porwal, P., Pachade, S., Kokare, M., Deshmukh, G., Son, J., Bae, W., Liu, L., Wang, J., Liu, X., Gao, L., Wu, T., Xiao, J., Wang, F., Yin, B., Wang, Y., Danala, G., He, L., Choi, Y. H., Lee, Y. C., ... Mériaudeau, F. IDRiD: Diabetic Retinopathy – Segmentation and Grading Challenge. *Med. Image Anal.*, 59, pp. 101561, 2020. <https://doi.org/10.1016/j.media.2019.101561>
- Rio Torres, M., Fernández Argones, L., Hernández Silva, J. R., y Ramos López, M. *Oftalmología: Diagnóstico y tratamiento* (2a ed.). Ciencias Médicas.
- World Health Organization. *WHO guideline: recommendations on digital interventions for health system strengthening*. World Health Organization.