

Aplicaciones de la Inteligencia Artificial en Ciencias de la Visión

Applications of Artificial Intelligence in Vision Sciences

Agustina Núñez Góngora, MSc^{1*}

1: Universidad de Valencia. Facultad de Física, España.

*nunezagustina12@gmail.com

Recibido: 25 de febrero del 2026

Aceptado: 16 de abril del 2026

Publicado: 18 de mayo del 2026

Financiación: Ninguno de los autores declaran tener financiaciones.

Declaración de Conflictos de Intereses: Ninguno de los autores declaran tener conflictos de intereses.

Relevancia: Analizar el impacto actual de la inteligencia artificial en las ciencias de la visión, destacando su utilidad en el diagnóstico y clasificación de patologías oculares.

Resumen: Mediante la realización de una búsqueda bibliográfica, se han evaluado las aplicaciones de la inteligencia artificial en las ciencias de la visión, destacando los aportes más relevantes de la inteligencia artificial a los diagnosticadores y los límites de esta. Se ha realizado la búsqueda bibliográfica, a través de la base de datos PubMed siguiendo la estrategia PRISMA, de artículos científicos publicados en los últimos veinte años. Se obtuvieron 431 artículos, de los cuales, mediante un proceso de selección, resultaron quedando un total de 26 artículos, que cumplieran los criterios de inclusión.

Después de analizar los artículos seleccionados y extraer la información de más relevancia de cada uno de ellos, he podido concluir que, para ciertas, la inteligencia artificial supone un gran avance tanto en el diagnóstico como en las clasificaciones de estas, siendo una gran ayuda para los diagnosticadores así como mejorando la calidad de vida de los pacientes y disminuyendo la probabilidad de ceguera. A esta conclusión podemos llegar viendo los resultados altos de AUC, especificidad y sensibilidad de diferentes modelos de aprendizaje profundo para el diagnóstico de dichas patologías.

A pesar de que la inteligencia artificial representa un gran avance en el diagnóstico de patologías, todavía se tienen que realizar más estudios para que los resultados de los modelos se acerquen más a la práctica clínica real, utilizando más diversidad de datos de pacientes y más imágenes de enfermedades multi categóricas.

Palabras clave: Inteligencia Artificial, Glaucoma, Catarata, Retinopatía, Degeneración Macular Asociada a la Edad (DMAE).

Relevance: To analyze the current impact of artificial intelligence in vision sciences, highlighting its utility in the diagnosis and classification of ocular pathologies.

Abstract: Through a structured literature review, the applications of artificial intelligence in vision sciences were evaluated, emphasizing its most relevant contributions to diagnostic processes as well as its current limitations. The literature search was conducted using the PubMed database, following the PRISMA strategy, including scientific articles published over the last twenty years. A total of 431 articles were identified; after a selection process based on predefined inclusion criteria, 26 articles were ultimately included in the analysis.

After reviewing the selected studies and extracting the most relevant information from each, it can be concluded that, for certain conditions, artificial intelligence represents a significant advancement in both diagnosis and classification. It serves as a valuable support tool for clinicians, while also contributing to improved

patient quality of life and a reduced risk of blindness. This conclusion is supported by the high values of AUC, specificity, and sensitivity reported by various deep learning models for the diagnosis of these pathologies.

Despite these advances, further research is required to ensure that model performance more closely reflects real-world clinical practice. This includes the use of more diverse patient data and a greater number of images representing multicategorical diseases.

Keywords: Artificial Intelligence, Glaucoma, Cataract, Retinopathy, Age-Related Macular Degeneration (AMD)

INTRODUCCIÓN

En este trabajo nos centraremos en la aplicación de la IA en las ciencias de la visión, describiendo en primer lugar la metodología utilizada para la obtención de los artículos de relevancia de los cuales extraeré la información necesaria, a continuación que es la Inteligencia Artificial, su relación con la Big Data y de cómo se benefician los profesionales del campo de la oftalmología y optometría de la IA a la hora de diagnosticar y tratar las patologías de sus pacientes y en último lugar, las limitaciones de esta y las conclusiones

El presente trabajo pretende recopilar la evidencia científica más relevante sobre los diferentes usos de la IA en el campo de la ciencia de la visión. Para la realización de este trabajo, se han buscado en diferentes bases de datos, artículos científicos relacionados con la IA, las ciencias de la visión y la relación entre estos dos campos, que respondan a la pregunta ¿Cuáles són las aplicaciones de la inteligencia artificial en el campo de las ciencias de la visión?

A continuación, se ha hecho una selección de los artículos y se ha extraído la información más relevante de cada uno de ellos. Se ha descrito la metodología utilizada con respecto a la búsqueda bibliográfica, al igual que los pasos seguidos.

Estrategia de búsqueda bibliográfica

Para la elaboración del trabajo se planteó la pregunta de investigación: "¿Cuáles son las aplicaciones de la inteligencia artificial en el campo de las ciencias de la visión?". Se realizó una búsqueda bibliográfica en las bases de datos PubMed y Scielo entre enero y junio de 2023, siguiendo las recomendaciones de la metodología PRISMA y utilizando palabras clave combinadas con operadores booleanos.

La búsqueda inicial arrojó 17.387 artículos. Tras aplicar filtros de publicación en los últimos 20 años y limitar a artículos científicos, se redujo la muestra a 341 estudios. Finalmente, después de evaluar su calidad, relevancia

y revisar referencias bibliográficas, se seleccionaron 40 artículos para el análisis final.

Inteligencia Artificial

La IA es una de las ramas científicas más recientes sobre la informática (1), que pretende realizar actividades propias del cerebro humano, sintetizando y automatizando tareas intelectuales, que van desde áreas generales, como aprendizaje y percepción, hasta tareas más específicas, como demostrar teoremas o diagnóstico de enfermedades (2)(3).

La IA desarrolla sistemas y algoritmos que puedan realizar tareas que normalmente requieren de la inteligencia humana, como el aprendizaje, razonamiento y capacidad de adaptación.

En la actualidad, muchos son los campos que se han visto beneficiados por este conjunto de técnicas, podemos destacar el ámbito de la imagen médica con sistemas capaces de reconocer, por ejemplo, patrones patológicos en una modalidad de imagen determinada y diagnosticar enfermedades de forma automatizada. (4)

Big Data

La Big Data está asociada a macrosistemas de gran escala con procesamiento de datos capaces de modificar, optimizar y generar métodos y modelos de almacenamiento y tratamiento de datos que compensan las carencias impuestas por la velocidad y el volumen de procesamiento de las bases de datos y los sistemas de gestión tradicionales, a la hora de hacer frente al crecimiento del volumen de datos generados por diferentes sistemas y la complejidad de los datos de muchas fuentes, como por ejemplo, internet, abarcando tanto volumen como variedad de datos y velocidad de acceso y procesamiento. (5)

El impacto social más importante de Big Data es su combinación con la IA. Usando datos que pueden venir de una gran variedad de fuentes como sensores, dispositivos móviles, redes sociales, bases de datos empresariales, entre otros, la Big Data se utiliza para analizar estos datos masivos, extraer información valiosa para mejorar los modelos de IA y tomar decisiones

informadas en una gran variedad de campos como la salud, la seguridad, los negocios y la ciencia. (6)

Inteligencia Artificial aplicada a las Ciencias de la Visión

En las últimas décadas muchas técnicas de imágenes médicas han desempeñado un papel fundamental en la detección, el diagnóstico y el tratamiento de enfermedades, como, por ejemplo, la tomografía computarizada, la resonancia magnética, la ecografía, la tomografía por emisión de positrones, tomografía de coherencia óptica y rayos X, que se combinan con la IA para la interpretación de las imágenes (4). En la tabla 1 podemos observar algunas de las técnicas comentadas anteriormente, que son utilizadas en oftalmología en combinación con la IA para el diagnóstico de enfermedades. (7)(8)

Algoritmos de la Inteligencia Artificial

- Aprendizaje automático: El ML es la imitación de la estructura neuronal del SNC mediante la creación de ANN. Una ANN es un sistema informático basado en neuronas artificiales organizadas en capas que transforman la señal a medida que viaja desde la capa de entrada (por ejemplo, datos clínicos del paciente) y la capa de salida (última), que podría representar un diagnóstico. (9)

- Aprendizaje profundo: El DL, es una tecnología naciente del ML que se desarrolló en 2012 como la nueva generación de redes neuronales profundas (DNN). Son una ANN, que entre las capas de entrada y salida, tienen múltiples capas intermedias, lo cual les permite que cada nivel aprenda a transformar su señal de entrada en una representación más abstracta y de mayor nivel, utilizando menos neuronas artificiales que una ANN superficial haciéndolas, de esta manera, más eficiente en el aprendizaje (10).

El DL posibilita un entrenamiento de extremo a extremo, ya que aprende directamente desde la señal de entrada sin necesidad de diseñar manualmente características específicas. Sin embargo, requiere grandes volúmenes de datos y presenta la limitación de ser considerado una "caja negra", debido a la dificultad de interpretar cómo genera sus resultados. (11)

- Convolutional Neural Network (CNN) o Redes Neuronales Convolucionales: La arquitectura de DL que se considera más adecuada para obtener imágenes de datos son las CNN ya que estas, codifican un patrón de conectividad entre neuronas que se parece a la organización de la corteza visual de los mamíferos. (4)

Las CNN constan de múltiples capas convolucionales que aplican una operación de filtrado matemático llamado convolución, esta hace que las neuronas individuales procesen los datos sólo para su subcampo receptivo e imita su respuesta a los estímulos visuales. Estos filtros

se comportan como detectores de características especiales y a medida que la imagen de entrada se procesa con sucesivas capas convolucionales de la red, los filtros en el proceso se apilan creando detectores de características cada vez más descriptivos y sofisticados. Por lo tanto, transforman las imágenes de entrada en mapas de características jerárquicas, desde características simples, como bordes y líneas, hasta características más complicadas, como formas y colores (12). También incluye capas que pueden combinar características similares en una, para reducir la variedad de las características extraídas y capas que pueden combinar estas características. (9)

Construcción de modelos de Inteligencia Artificial

Las fases del procesamiento de las imágenes son las siguientes:

- Preprocesamiento de datos: Procesar los datos que no han sido procesados previamente, ya que si no, podríamos encontrarnos artefactos. (13)

- Segmentación: Separación de la imagen en regiones de características similares. (9)

- Clasificación: A partir de un conjunto de datos obtenidos de la región segmentada, la asignación de dicha región a un grupo el cual se denomina clase, por ejemplo, en el caso de imagen médica puede ser la identificación de un tipo de tejido o lesión.

- Entrenamiento, Validación y Prueba: Para evaluar un modelo, se utilizan conceptos como la curva característica operativa del receptor (ROC), esta herramienta visualiza todas las combinaciones posibles de sensibilidad y especificidad del modelo a elegir para la utilización deseada. Esta herramienta nos sirve para representar el rendimiento de los algoritmos y se crea trazando la probabilidad de detección de cada algoritmo a lo largo de un continuo de umbral. Para cada umbral, la sensibilidad y la especificidad se representan gráficamente una frente a la otra. Sin embargo, para medir el rendimiento general de un modelo, independientemente de un umbral y una aplicación específicos, se utiliza el área bajo la curva ROC (AUC). El AUC es la métrica de evaluación más utilizada para la evaluación cuantitativa de un modelo en el diagnóstico de IA, los resultados de AUC de modelos efectivos oscilan entre 0,5, que corresponde a una suposición aleatoria y 1, que representa el 100% de sensibilidad y especificidad, lo que significa que el un modelo es preventivo y útil. (14)

Aplicaciones clínicas de la Inteligencia Artificial en patologías oculares

- Retinopatía Diabética:

A nivel mundial, actualmente más de 415 millones de

personas tienen diabetes en todo el mundo, de los cuales un tercio tiene retinopatía diabética. (15)

A continuación, comentaremos la tabla 3, donde podemos ver los autores, el año, la cantidad de imágenes utilizadas, las CNN utilizadas, el AUC, la especificidad y la sensibilidad de diferentes sistemas de DL, con diferentes bases de datos.

En primer lugar, para el año 2016, Abramoff et al. (16) demostraron con el conjunto de datos de Messidor-2 y el CNN AlexNet y VGG, se podía alcanzar un AUC de 0,980, con una sensibilidad de 96,8% y una especificidad del 87,0 %, en la detección de retinopatía diabética referible. (15)

Ese mismo año, Gulshan et al (17), informaron sobre otro sistema DL con un excelente rendimiento de diagnóstico. El sistema DL se desarrolló utilizando 128.175 imágenes de la retina, calificadas entre 3 y 7 veces para DR y DMO por 54 oftalmólogos con licencia de EE. UU y residentes de oftalmología. (15)

El conjunto de pruebas constaba de aproximadamente 10.000 imágenes recuperadas de dos bases de datos (EyePACS-1 y Messidor-2), calificadas por al menos siete oftalmólogos certificados por la junta de EE. UU.

Para EyePACS, el AUC fue de 0,991, la sensibilidad 90,30% de y la especificidad de 98,10% y para Messidor-2 un AUC de 0,99, una sensibilidad 87% de y una especificidad de 98,50% . Un año más tarde, Gargeya y Leng (18), con Kaggle Images, informaron un AUC de 0,97 usando validación cruzada, 0,94 en el Messidor-2 y en el E-Ophtha 0,96.

El estudio más grande hasta la fecha entre las publicaciones mencionadas fue realizado por Ting et al (19), estos informaron un rendimiento de diagnóstico clínicamente aceptable de un sistema de DL, desarrollado y probado utilizando el Programa Integrado de retinopatía diabética de Singapur durante un período de 5 años, y 10 conjuntos de datos externos reclutados de 6 países diferentes. Se informó que el sistema DL, desarrollado con la arquitectura VGG-19, tiene un AUC de 0,936, una sensibilidad de 90,5% y una especificidad de 91,6%. (15)

Para la retinopatía diabética que amenaza la visión, las estadísticas correspondientes fueron un AUC de 0,958, una sensibilidad de 100% y una especificidad de 91,1%. El AUC osciló entre 0,889 y 0,983 para los 10 conjuntos de datos externos.

Más recientemente, el sistema DL desarrollado por Abramoff et al, ha obtenido la aprobación de la FDA para el diagnóstico de retinopatía diabética, consiguiendo una sensibilidad del 87,2% y una especificidad del 90,7%. (15)

Actualmente, existen más de siete sistemas automatizados que han dado buenos resultados. Se obtuvo la aprobación de la FDA de los EEUU para los

sistemas IDx-DR AI y el EyeArt AI. (20)

- Degeneración Macular Asociada a la Edad (DMAE):

La DMAE es una de las principales causas de discapacidad visual en la población geriátrica en todo el mundo (15) la cual, se presta a la detección basada en IA. Varias publicaciones informan sobre la detección automatizada de DMAE en fotografías en color con una sensibilidad del 93% y una especificidad del 89% y con una precisión del 90%. (9)

La investigación de la IA que usa OCT para detectar la DMAE incluye la de Venhuizen et al (21), el cual obtuvo una sensibilidad y especificidad del 93% cada uno, frente a su referencia, que era un examen por un oftalmólogo. Este sistema se desarrolló en una base de datos de 3.265 escaneos de OCT (21).

En el año 2017, Ting et al (19), utilizando la arquitectura de VGG-19, obtuvieron unos resultados de una AUC de 0,932, una especificidad de 88,70% y una sensibilidad de 93,20%.

Burlina et al. (22), reportaron un diagnóstico precisión de entre 88,4% y 91,6%, con un AUC de entre 0,94 para AlexNet y 0,96 para Overfeat.

Usando AREDS (del inglés: Age-Related Eye Disease), un estudio que enfermedades oculares relacionadas con la edad, Grassmann et al (23) informaron una sensibilidad del 84,2% en la detección de cualquier DMAE. En este estudio, los autores utilizaron seis redes neuronales convolucionales (AlexNet, GoogleNet, VGG, Inception-V3, ResNet e Inception-ResNet-V2) para entrenar diferentes modelos. Los resultados fueron, una sensibilidad de 84,20% y una especificidad de 94,30% . Para el conjunto de datos AREDS, todas las fotografías fueron capturadas como fotografías analógicas y luego digitalizadas más tarde.

- Glaucoma:

El glaucoma es una enfermedad irreversible del nervio óptico, clasificada por la excavación de este y la erosión del borde neuro retiniano que se presenta a consecuencia del aumento de las ventosas de la cabeza del nervio óptico. (15)

Los algoritmos de la IA para detectar glaucoma, se basan en las mismas características retinianas que los oftalmólogos, que son la relación C/D, el área del borde neuro retiniano y la regla ISNT, evaluando la distribución del ancho del borde neural alrededor de la cabeza del nervio óptico. (9)

Isaac et al. clasificó el glaucoma basado en IA utilizando las tres características comentadas anteriormente en 67 ojos, de los cuales 32 eran patológicos, para la diferenciación entre pacientes con y sin glaucoma. De esta manera obtuvieron unos resultados con una precisión, una sensibilidad y especificidad del 94 %.

| SISTEMA DL | AÑO | CONJUNTOS DE DATOS DE PRUEBA | IMÁGENES DE PRUEBA (n) | CNN | AUC | SENSIBILIDAD | ESPECIFICIDAD |
|----------------|-------|---|------------------------|----------------|-------|--------------|---------------|
| Abràmoff et al | 2016 | Messidor-2 | 1.748 | AlexNet/VGG | 0.98 | 96.80 | 87 |
| Gulshan et al | 2016 | Messidor-2 | 1.748 | Inception-V3 | 0.99 | 87 | 98.50 |
| | | EyePacs-1 | 9.963 | | 0.991 | 90.30 | 98.10 |
| Gargeya y Leng | 2017 | Kaggle images | 75.137 | Customised CNN | 0.97 | NA | NA |
| | | E-Ophtha | 463 | | 0.96 | NA | NA |
| | | Messidor-2 | 1.748 | | 0.94 | NA | NA |
| Ting et al | 2017 | SiDRP 14-15 | 71.896 | VGG-19 | 0.936 | 90.50 | 91.60 |
| | | Guangdong | 15.798 | | 0.949 | 98.70 | 81.60 |
| | | SIMES | 3.052 | | 0.889 | 97.10 | 82 |
| | | SINDI | 4.512 | | 0.917 | 99.30 | 73.3 |
| | | SCES | 1.936 | | 0.919 | 100 | 76.33 |
| | | BES | 1.052 | | 0.929 | 94.40 | 88.50 |
| | | AFEDS | 1.968 | | 0.98 | 98.80 | 86.50 |
| | | RVEEH | 2.302 | | 0.983 | 98.90 | 92.20 |
| | | Mexican | 1.172 | | 0.95 | 91.80 | 84.80 |
| | | CUHK | 1.254 | | 0.948 | 99.3 | 83.10 |
| HKU | 7.706 | 0.964 | 100 | 81.30 | | | |
| Abràmoff et al | 2018 | Sitios de práctica de atención primaria de EE. UU | 892 pacientes | Alex/VGG | NA | 87.2 | 90.7 |

Tabla 1: Sistemas de DL en la detección referible de Retinopatía diabética.

DL: Deep Learning (Aprendizaje Profundo); CNN: Convolutional Neural Network (Redes Neuronales Convolucionales); AUC: Area Under the Curve (Área Bajo la Curva); NA: No Aplicable.

Por lo tanto, la combinación de las tres características mencionadas anteriormente con los cambios en la capa de fibras nerviosas de la retina también tiene un gran potencial.

Bowd et al. también aplicó su enfoque algorítmico a la combinación de OCT y datos de campo visual en un conjunto de datos de 69 participantes de control sanos y 156 pacientes con glaucoma y probó su algoritmo para OCT solo, campo visual solo y una combinación de ambos. Los resultados fueron los siguientes; Para la OCT solo obtuvo una precisión del 82%, el CV solo, una precisión del 84% y la combinación de ambas una precisión del 87%. (9)

En el año 2017 y 2018, como podemos observar en la tabla 5, Ting et al (19) y Li et al (24), entrenaron una computadora con algoritmos para detectar discos

patológicos por glaucoma, definido como una CDR vertical de 0,8 y 0,7, respectivamente. De esta manera, Ting et al. obtuvo un resultado de AUC de 0,942, una sensibilidad del 96,40% y una especificidad del 93,20%. En cambio Li et al, obtuvo un resultado de AUC de 0,986, una sensibilidad del 95,60% y una especificidad del 92%. Chen et al, obtuvo una AUC de 0.831 con el Oringa y 0.887 con Escenas, ambos con la arquitectura DCNN. (15)

Elze et al. desarrollaron un programa informático no supervisado para analizar el campo visual que puede reconocer patrones de pérdida importantes clínicamente y asigna un coeficiente de ponderación para cada uno, lo cual ha demostrado ser útil en la detección de la pérdida temprana de campo visual por

| SISTEMA DL | AÑO | CONJUNTOS DE DATOS DE PRUEBA | IMÁGENES DE PRUEBA (n) | CNN | AUC | SENSIBILIDAD | ESPECIFICIDAD |
|-----------------|------|------------------------------|------------------------|--|-----------|--------------|---------------|
| Ting et al | 2017 | SiDRP 14-15 | 35.948 | VGG-19 | 0.932 | 96.40 | 93.20 |
| Burlina et al | 2017 | AREDS | 120.656 | AlexNet, OverFeat | 0.94-0.96 | NA | NA |
| Grassmann et al | 2018 | AREDS | 120.656 | AlexNet, GoogleNet, VGG, Inception-V3, ResNet, Inception-ResNet-V2 | NA | 84.20 | 94.30 |
| Treder et al | 2018 | 5D-OCT | 1.112 | DCNN | NA | 100 | 92 |

Tabla 2: Sistemas de DL en la detección referible de Degeneración Macular Asociada a la Edad (DMAE). DL: Deep Learning (Aprendizaje Profundo); CNN: Convolutional Neural Network (Redes Neuronales Convolucionales); AUC: Area Under the Curve (Área Bajo la Curva); NA: No Aplicable.

| SISTEMA DL | AÑO | CONJUNTOS DE DATOS DE PRUEBA | IMÁGENES DE PRUEBA (n) | CNN | AUC | SENSIBILIDAD | ESPECIFICIDAD |
|------------|------|------------------------------|------------------------|-----------|-------|--------------|---------------|
| Ting et al | 2017 | SiDRP 14-15 | 71.896 | VGG-19 | 0.942 | 96.40 | 93.20 |
| Li et al | 2018 | Guangdong | 48.116 | GoogleNet | 0.986 | 95.60 | 92 |
| Chen et al | 2018 | Origa | 2.326 | DCNN | 0.831 | NA | NA |
| | | Escenas | 2.326 | DCNN | 0.887 | NA | NA |

Tabla 3: Sistemas de DL en la detección referible de glaucoma.

DL: Deep Learning (Aprendizaje Profundo); CNN: Convolutional Neural Network (Redes Neuronales Convolucionales); AUC: Area Under the Curve (Área Bajo la Curva); NA: No Aplicable.

| SISTEMA DL | AÑO | CONJUNTOS DE DATOS DE PRUEBA | IMÁGENES DE PRUEBA (n) | CNN | AUC | SENSIBILIDAD | ESPECIFICIDAD |
|-------------|------|------------------------------|------------------------|----------------------|-----|--------------|---------------|
| Brown et al | 2018 | i-ROP | 100 | Inception-V1 y U-Net | NA | 100 | 94 |

Tabla 4: Sistemas de DL en la detección referible de Retinopatía del Prematuro (ROP).

DL: Deep Learning (Aprendizaje Profundo); CNN: Convolutional Neural Network (Redes Neuronales Convolucionales); AUC: Area Under the Curve (Área Bajo la Curva); NA: No Aplicable.

| SISTEMA DL | AÑO | CONJUNTOS DE DATOS DE PRUEBA | IMÁGENES DE PRUEBA (n) | CNN | AUC | SENSIBILIDAD | ESPECIFICIDAD |
|-------------|-----|------------------------------|------------------------|------|-----|--------------|---------------|
| Gao et al | - | ACHIKO-NC | 2.378 | - | 0 | 96.40 | 93.20 |
| Largo et al | - | Guangdong | - | DCNN | 0 | 95.60 | 92 |

Tabla 5: Sistemas de DL en la detección referible de la catarata.

DL: Deep Learning (Aprendizaje Profundo); CNN: Convolutional Neural Network (Redes Neuronales Convolucionales); AUC: Area Under the Curve (Área Bajo la Curva); NA: No Aplicable.

glaucoma.

Yousefi et al desarrollaron un algoritmo basado en una máquina que detectó la progresión del campo visual antes que estas estrategias convencionales.

Kazemian et al (25) desarrollaron una técnica de pronóstico clínico que utiliza datos tonométricos y de campo visual para proyectar trayectorias de la enfermedad en diferentes PIO objetivo.

- Retinopatía del prematuro:

Como vemos en la tabla 6, Brown et al (26) informaron de los resultados de un sistema de DL para diagnosticar la enfermedad. El sistema i-ROP DL, el cual demostró ser prometedor para el control objetivo de la enfermedad, el algoritmo tenía una sensibilidad del 100% y una especificidad del 94%. (15)

Comparado directamente con ocho expertos internacionales en diagnóstico de retinopatía del prematuro, el sistema i-ROP DL estuvo de acuerdo con el diagnóstico de consenso con más frecuencia que seis de ocho expertos.

Ataer-Cansizoglu et al (27) en el 2015, fue quien desarrolló el sistema i-ROP. Para ello, la IA se aplicó en un conjunto de datos de 77 imágenes retinianas de gran angular de bebés y se comparó con exámenes oftalmoscópicos, así como con tres clasificaciones manuales de cada imagen. El sistema i-ROP logró una precisión del 95 % para clasificar ROP frente a no ROP en comparación con el examen de fondo de ojo. Esto fue comparable al desempeño de tres expertos humanos (96%, 94%, 92% de precisión). En un segundo enfoque, el sistema i-ROP se evaluó frente a más expertos humanos con una precisión del 79 % al 99 %, en este caso se utilizaron menos características para el diagnóstico. La precisión que se había obtenido al principio, del 95%, no se pudo lograr, por lo tanto, se concluyó que el uso de todas las características conocidas da como resultado el diagnóstico de más fiabilidad. (15)

Los dos estudios mencionados solo se han comparado

con la clasificación especializada de la imagen, no con el examen clínico. Por lo tanto, existe un gran potencial para el establecimiento de programas de detección automática de retinopatía del prematuro en el futuro, ya que la mayoría de las clínicas ya tienen cámaras disponibles y se puede lograr un resultado preciso para estas imágenes. (15)

- Catarata:

La catarata es una área del cristalino opacificada, la cual causa síntomas en las personas que la padecen, produciendo una disminución de la calidad de vida. Para el diagnóstico y la clasificación de la catarata a partir de imágenes del fondo de ojo, de ultrasonidos e imágenes oculares de longitud de onda visible, se ha aplicado algoritmos de ML. Los investigadores ahora pueden usar modelos DL para diagnosticar la catarata pediátrica, gracias a Largo et al., los cuales construyeron un marco de diagnóstico asistido por computadora basado en DCNN para clasificar las cataratas pediátricas. Como vemos en la tabla 7, obtuvo una sensibilidad del 95,60 y una especificidad del 92%. (4)

Límites de la Inteligencia Artificial

Teniendo en cuenta que en la vida real los pacientes generalmente sufren de enfermedades multi categóricas, una de las principales limitaciones de la IA, es que actualmente no se ha desarrollado un sistema capaz de detectar más de una enfermedad individual, a pesar de que la precisión de los modelos sea excelente a la hora de identificarlas. Por ejemplo, si tenemos un paciente con DMAE y glaucoma, el modelo que se ha entrenado para detectar DMAE, no podrá detectar el glaucoma como enfermedad porque este habra sido entrenado para discriminar DMAE de NO DMAE.

Choi et al. llevaron a cabo un estudio aplicando DL para detectar automáticamente múltiples enfermedades de la retina diferentes con fotografías del fondo de ojo. Cuando sólo se incluyeron imágenes de fondo de ojo

normal y DR en el modelo de DL propuesto, la precisión de la clasificación fue del 87,4%. Sin embargo, la precisión cayó al 30,5 % cuando se incluyeron más categorías. Esto indica que la precisión del modelo disminuyó a medida que el número de enfermedades aumentaba.

(4) Por lo tanto, las imágenes clínicas multimodales, como, por ejemplo, el campo visual y las imágenes de fondo de ojo, deben integrarse para construir un sistema de IA generalizado para un diagnóstico de IA más confiable. No obstante, otra limitación es la gran cantidad de datos que se necesitan para lograr este objetivo y más, teniendo en cuenta que las imágenes con enfermedades graves o enfermedades poco comunes son particularmente insuficientes. También cabe añadir, que se necesitan más conjuntos de datos más grandes, es decir, de poblaciones de pacientes más diversas, de diferentes entornos, condiciones y etnias.

Otro límite de la IA ya comentado anteriormente, es que, en los métodos basados en DL, a pesar de que muestran excelentes resultados, su naturaleza de "caja negra" dificulta la interpretación de los algoritmos y la comprensión de sus decisiones.

En último lugar, comentar los problemas éticos, regulatorios y legales de las aplicaciones de la IA en este campo, dado que sin duda generará un impacto clínico significativo en el futuro cercano.

de la IA y profundizar en el estudio de estas, como por ejemplo, aportando más datos, como hemos dicho anteriormente, tanto de más diversidad de pacientes, así como más imágenes de enfermedades multicategorías, para acercarnos más a la práctica clínica real.

DISCUSIÓN

La IA ha demostrado ser una herramienta con un gran potencial diagnóstico y con una elevada eficacia a la hora de identificar diversas enfermedades oculares, ayudando a reducir también la prevalencia de las etapas tardías de estas. En las patologías oculares comentadas en este trabajo, como, la retinopatía diabética, la DMAE, la retinopatía del prematuro, el glaucoma y las cataratas, he comentado varios modelos de IA que contribuyen en la detección de estas. Si hacemos una media del AUC, la sensibilidad y la especificidad de los estudios comentados, obtenemos una media de 0,954, 99.3% y 85,2% respectivamente, los cuales corresponden a muy buenos resultados.

CONCLUSIONES

La investigación apunta a que la IA se irá convirtiendo en una ayuda imprescindible en el campo de las imágenes médicas, ya que como hemos visto, tiene un gran potencial para automatizar dicha práctica médica, a la hora de diagnosticar y evaluar diferentes patologías oculares.

No obstante, se tendrá que evaluar qué tareas dentro de este campo tienen más probabilidades de beneficiarse

REFERENCIAS

1. Mariño S, Primorac C. Propuesta metodológica para desarrollo de modelos de redes neuronales artificiales supervisadas. IJERI: International Journal of Educational Research and Innovation. 2016, 6:231-245.
2. Ocana-Fernandez Y, Valenzuela-Fernandez L, Garro-Aburto LL. Inteligencia artificial y sus implicaciones en la educación superior. Propós. represent. 2019, 7(2):536-568.
3. Lu W, Tong Y, Yu Y, et al. Applications of Artificial Intelligence in Ophthalmology: General Overview. J Ophthalmol. 2018.
4. Marcelo E. Andía, Cristóbal Arrieta, Carlos A. Sing Long, Una guía conceptual para usar y entender Big Data en la investigación clínica, Revista Médica Clínica Las Condes. 2019, 30(1):83-94
5. van der Velden BHM, Kuijff HJ, Gilhuijs KGA, Viergever MA. Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. Med Image Anal. 2022;79:102470.
6. Ting DSW, Pasquale LR, Peng L, et al. Artificial intelligence and deep learning in ophthalmology. The British journal of ophthalmology. 2019, 103(2):167–175.
7. Yu S, Tan KK, Ban LS, et al. Feature extraction and classification for ultrasound images of lumbar spine with support vector machine. Proceedings of 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Chicago, USA. 2014:4659–4662.
8. Litjens G. Una encuesta sobre el aprendizaje profundo en el análisis de imágenes médicas. Medicina. Imagen Anal 42. 2017:60–88
9. Barragán-Montero A, Javaid U, Valdés G, et al. Artificial intelligence and machine learning for medical imaging: A technology review. Phys Med. 2021;83:242-256.
10. Gulshan V, Peng L, Coram M, et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. JAMA. 2016;316(22):2402-2410.
11. Hajian-Tilaki K. Análisis de la curva característica operativa del receptor (ROC) para la evaluación de pruebas de diagnóstico médico. Revista del Caspio de Medicina Interna. 2013;4(2):627–635.
12. Quéllec G, Charrière K, Boudi Y, et al. Extracción de imágenes profundas para la detección de la retinopatía diabética. Análisis de imágenes médicas. 2017;39:178–193.
13. Molina-Casado JM, Carmona EJ, García-Feijó J. Fast detection of the main anatomical structures in digital retinal images based on intra- and inter-structure relational knowledge. Comput Methods Programs Biomed. 2017;149:55-68.
14. Moccia S, De Momi E, El Hadji S, et al. Blood vessel segmentation algorithms — Review of methods, datasets and evaluation metrics. Blood vessel segmentation algorithms - Review of methods, datasets and evaluation metrics. Comput Methods Programs Biomed. 2018;158:71–91.
15. Ramesh AN, Kambhampati C, Monson JRT, et al. Artificial intelligence in medicine. Artificial intelligence in medicine. Ann R Coll Surg Engl. 2004;86(5):334–338.
16. Ting DSW, Cheung CY, Lim G, et al. Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes. JAMA 2017;318:2211–23.
17. Abramoff MD, Lavin PT, Birch M, et al. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. NPJ Digit Med 2018;1:1–8.
18. Venhuizen FG, van Ginneken B, van Asten F, et al. Automated staging of age-related macular degeneration using optical coherence tomography. Automated staging of age-related macular degeneration using optical coherence tomography. Invest Ophthalmol Vis Sci. 2017;58(4):2318–2328.
19. Burlina PM, Joshi N, Pekala M, et al. Automated grading of age-related macular degeneration from color fundus images using deep convolutional neural networks. JAMA Ophthalmol 2017;135:1170–6
20. Redd TK, Campbell JP, Chiang MF. Artificial Intelligence for Refractive Surgery Screening: Finding the Balance Between Myopia and Hype-ropia. JAMA Ophthalmol. 2020;138(5):526-527.
21. Li Z, He Y, Keel S, et al. Efficacy of a deep learning system for detecting glaucomatous optic neuropathy based on color fundus photographs. Ophthalmology 2018;125:1199–206
22. Kazemian P, Lavieri MS, Van Oyen MP, et al. Personalized prediction of glaucoma progression under different target intraocular pressure levels using filtered forecasting methods. Ophthalmology 2018;125:569–77
23. Brown JM, Campbell JP, Beers A, et al. Automated diagnosis of plus disease in retinopathy of prematurity using deep convolutional neural networks. JAMA Ophthalmol 2018;136:803–10.
24. Ataer-Cansizoglu E, Bolon-Canedo V, Campbell JP, et al. Computer-based image analysis for plus disease diagnosis in retinopathy of prematurity: performance of the “i-ROP” system and image features associated with expert diagnosis. Ophthalmology. 2015;122(9):1791–1798.
25. Centers for Medicare & Medicaid Services. data.cms.gov. Disponible en: <https://data.cms.gov/provider-summary-by-type-of-service>
26. Wichmann W, Müller-Forell W. Anatomy of the visual system. Eur J Radiol. 2004;49:8–30.
27. Legrá D, Julke R, Legrá Legrá Y, et al. La tomografía de coherencia óptica en el estudio de patologías neurooftalmológicas. Revista Información Científica. 2013;77(1)

ABREVIATURAS

- IA: Inteligencia artificial
- TC: Tomografía computarizada
- RM: Resonancia magnética
- DMAE: Degeneración macular asociada a la edad
- OCT: Tomografía de coherencia óptica
- PIO: Presión intraocular
- FDA: *Food and Drug Administration* (Administración de Comida y Medicamentos)
- SNC: Sistema nervioso central
- ML: *Machine learning* (Aprendizaje automático)
- DL: *Deep learning* (Aprendizaje profundo)
- ANN: *Artificial Neuronal Network* (Red neuronal artificial)
- DNN: *Deep Neuronal Network* (Red neuronal profunda)
- CNN: *Convolutional Neural Network* (Redes Neuronales Convolucionales)
- AUC: *Area Under the Curve* (Área bajo la curva)