

Maria Capdevila Bages

“Inteligencia Artificial aplicada a la Degeneración Macular Asociada a la Edad (DMAE) seca”: una Revisión Bibliográfica

TRABAJO DE FIN DE GRADO

Dirigido por el Dr. Baget Bernaldiz

DEPARTAMENTO DE OFTALMOLOGÍA

Grado de Medicina



UNIVERSITAT ROVIRA i VIRGILI

Reus, 2020

Índice

ABSTRACT	3
INTRODUCCIÓN	3
Prefacio	4
Degeneración Macular Asociada a la Edad (DMAE)	4
Inteligencia Artificial y <i>Deep Learning</i>	6
Redes neurales.....	6
Aplicaciones en Salud y Oftalmología.....	7
Reconocimiento de imágenes	8
HIPÓTESIS Y OBJETIVOS	9
METODOLOGÍA	10
Primera parte: revisión bibliográfica	10
Búsqueda de literatura	10
Selección de estudios	10
Segunda parte: proceso de investigación.....	11
Extracción de datos	11
Análisis estadístico.....	11
RESULTADOS	12
1. IA en el cribado y diagnóstico de la DMAE	12
2. IA en el pronóstico y tratamiento de la DMAE	16
3. IA en el seguimiento y monitorización domiciliar de la DMAE.....	17
DISCUSIÓN	18
Limitaciones.....	21
CONCLUSIONES	22
AGRADECIMIENTOS	23
REFERENCIAS BIBLIOGRÁFICAS	24
Índice de figuras.....	27

ABSTRACT

CASTELLANO

Introducción: la introducción de la inteligencia artificial en la medicina y particularmente en oftalmología constituye una innovación tecnológica prometedora con un gran potencial, que en un futuro próximo estará cada vez más presente en la profesión. Su aplicación en la creación de redes de convolución profunda para el procesamiento de imágenes oculares en el contexto de la degeneración macular asociada a la edad (DMAE) abre un camino lleno de posibilidades. **Objetivos:** valorar la utilidad de la IA en el cribado, diagnóstico, pronóstico y seguimiento de la DMAE seca. **Metodología:** se realizó una búsqueda de bibliografía específica en PubMed mediante 3 estrategias de búsqueda avanzada y posteriormente se agruparon los estudios en 3 categorías para su análisis. Se recopilaron las características básicas de los estudios y los índices de evaluación de los algoritmos y se procedió a su comparación, principalmente mediante los valores de precisión. **Resultados:** el procesamiento de imágenes de retinografías y OCT mediante sistemas de IA para el diagnóstico de DMAE muestra unos resultados de precisión excelentes (de 0,633 a 0,992 y de 0,826 a 0,992 respectivamente), comparables e incluso a veces superiores a los de especialistas en retina altamente capacitados. En cuanto al pronóstico, el procesamiento de imágenes de OCT permite una predicción fiable del riesgo de progresión hacia la variante atrófica o neovascular específicamente. En el campo de la telemedicina se han desarrollado sistemas de IA para su uso a través de la nube con resultados satisfactorios. **Conclusiones:** la IA ha demostrado resultados excelentes en todos los campos de aplicación con relación a la DMAE.

Palabras clave: Inteligencia artificial (IA); Aprendizaje profundo; Red neuronal convolucional profunda; Degeneración macular asociada a la edad (DMAE); Retinografía; Tomografía de coherencia óptica (OCT); Autofluorescencia; Cribado; Diagnóstico; Pronóstico; Seguimiento.

ENGLISH

Background: the introduction of artificial intelligence in medicine and particularly in ophthalmology constitutes a promising technological innovation with a huge potential that will be increasingly present in this profession in the near future. Its application in the creation of convolutional neural networks (CNN) for the processing of ocular images in the context of age-related macular degeneration (AMD) opens a path full of possibilities. **Purpose:** to assess the usefulness of AI in the screening, diagnosis, prognosis, and follow-up of dry ARMD. **Methods:** a specific literature search was performed in PubMed using 3 advanced search strategies and the studies were subsequently grouped into 3 categories for analysis. The basic characteristics of the studies and the evaluation indices of the algorithms were compiled, and their comparison was carried out mainly through precision values. **Results:** the processing of fundus and OCT images using AI systems for the diagnosis of AMD shows excellent accuracy results (0,633 to 0,992 and 0,826 to 0,992 respectively), comparable and sometimes even superior to those of highly trained retina specialists. Regarding prognosis, OCT image processing allows a reliable prediction of the risk of progression towards the atrophic or neovascular variant specifically. In the field of telemedicine, AI systems have been developed for their use through the cloud with satisfactory results. **Conclusions:** AI has shown excellent results in all fields of application in relation to AMD.

Keywords: Artificial intelligence (AI); Deep learning (DL); Convolutional neural network (CNN); Age-related macular degeneration (ARMD); Retinography; Fundus images; Optical coherence tomography (OCT); Autofluorescence; Screening; Diagnosis; Prognosis; Follow-up.

INTRODUCCIÓN

Prefacio

La Inteligencia Artificial (IA) basada en el concepto del aprendizaje profundo (“*Deep Learning*”, DL) ha suscitado un interés creciente durante los últimos años. Se trata de un campo de estudio emergente que equipara las funciones de los ordenadores a la inteligencia humana. Sin embargo, la inteligencia artificial tiene un potencial inmenso que sobrepasa el mero objetivo de imitar nuestras capacidades, pues esta tecnología posibilita el procesamiento de datos más allá de la comprensión del cerebro humano.

La oftalmología siempre se ha encontrado a la vanguardia en innovación tecnológica, desde el uso terapéutico del láser y la microcirugía hasta las primeras aplicaciones de terapias génicas y con células madre. Tanto es así que, hoy en día, se considera entre las especialidades líderes en la aplicación del *Deep Learning* en el ámbito de la Salud.

Degeneración Macular Asociada a la Edad (DMAE)

La Degeneración Macular Asociada a la Edad (DMAE) es, como su nombre indica, una enfermedad degenerativa de la mácula que provoca la consecuente pérdida progresiva de la visión central (Figura 1). Se trata de una enfermedad con una importancia de primer orden por su elevada prevalencia, impacto en la calidad de vida y repercusión para el sistema sanitario. Además, podría ser considerada como una “urgencia oftalmológica” dada su rápida progresión.

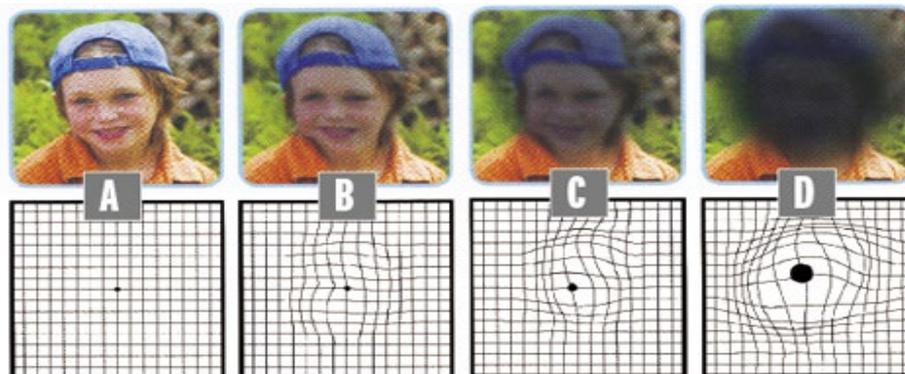


Figura 1. Progresión de la visión en la DMAE húmeda. Fuente: Mácula-Retina, Asociación de Enfermos y Familiares.

En España se le estima una prevalencia del 1,5% en la población general, la cual aumenta con la edad –siendo este su principal factor de riesgo–, alcanzando valores del 17% si se considera la población mayor de 65 años (Figura 2)². Así, la DMAE constituye la primera causa de ceguera legal a partir de los 50 años en países desarrollados. Además, las previsiones de la OMS sugieren que a lo largo de las próximas décadas la DMAE triplicará su prevalencia como consecuencia del incremento en la longevidad de las sociedades industrializadas.

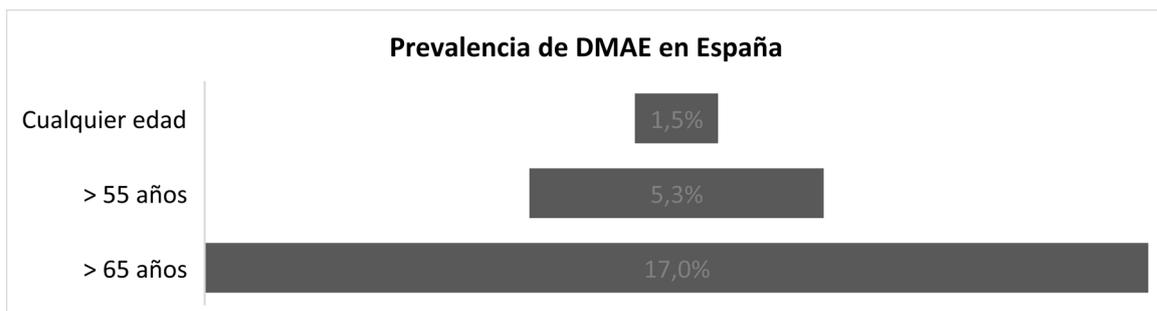


Figura 2. Prevalencia de DMAE en España. Fuente: elaboración propia.

Esta enfermedad, que afecta al complejo fotorreceptores – epitelio pigmentario retiniano (EPR) – membrana de Bruch – coroides, tiene su base fisiopatológica en procesos inflamatorios y oxidativos a nivel macular, los cuales provocan la degeneración de estas células con la consecuente repercusión en la función visual. Básicamente, algún defecto en el metabolismo de los fotorreceptores conduce a la acumulación de detritus o sustancias de deshecho, las drusas, que a largo plazo terminan dañando el EPR.

La DMAE cuenta con un amplio espectro de presentación, si bien la mayoría de pacientes sufren formas leves o moderadas. Clásicamente se han descrito dos tipos de DMAE: seca y húmeda; no obstante, en la actualidad y desde el año 2013, a raíz de la propuesta de Ferris et al.⁴ obtenida a partir del consenso de expertos mediante el método Delphi, esta se clasifica según su gravedad en tres estadios: precoz, intermedia y avanzada (Figura 3).

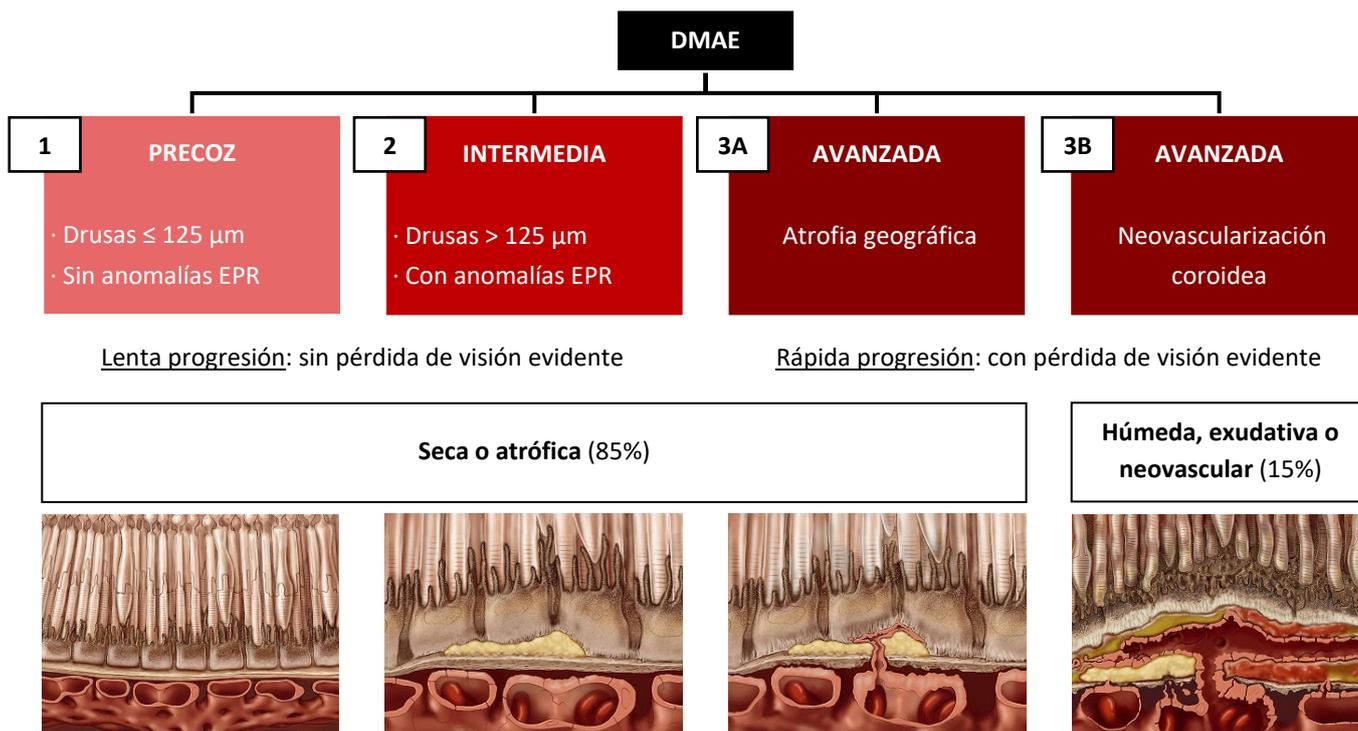


Figura 3. Estadios de DMAE según Ferris et al.⁴ (2013). Fuente: elaboración propia.

Esta clasificación se basa en las lesiones observadas en el examen del fondo de ojo localizadas dentro de hasta dos diámetros de disco respecto al centro de la fóvea en personas mayores de 55 años (Tabla 1).

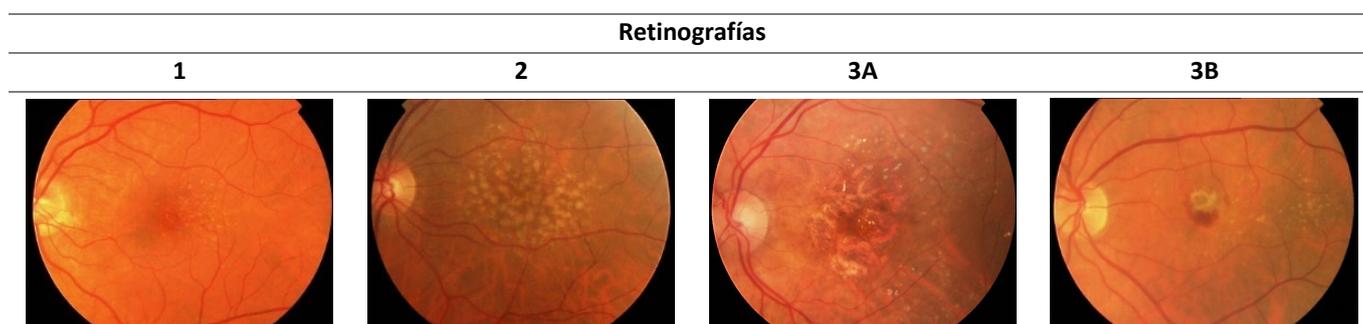


Tabla 1. Retinografías de los estadios de DMAE según Ferris et al.⁴ (2013). Fuente: elaboración propia.

En cuanto al diagnóstico, cada estadio de la DMAE puede beneficiarse de unas pruebas de imagen más adecuadas para la detección de alteraciones específicas (Tabla 2), si bien en el examen básico de esta patología nunca podrá faltar la valoración de la agudeza visual ni tampoco un fondo de ojo con dilatación de la pupila o mediante cámara no midriática.

	DMAE seca	DMAE húmeda
Retinografía	Sí	Sí
Autofluorescencia	Sí	Sí
Angiografía fluoresceínica	Sí	Sí
Tomografía de Coherencia Óptica	Sí	Sí
Angiografía por Tomografía de Coherencia Óptica	No	Sí

Tabla 2. Utilidad de distintas pruebas de imagen en el diagnóstico de la DMAE seca y húmeda. Fuente: elaboración propia.

Esta revisión se centra en la DMAE seca, por lo que las pruebas diagnósticas en las cuales se va a profundizar son las que permiten la obtención de imágenes de utilidad (analizables mediante IA) en esta fase de la enfermedad, es decir: la retinografía, la autofluorescencia, la angiografía fluoresceínica y la tomografía de coherencia óptica.

Otra técnica emergente prometedora pero aún poco extendida en la práctica clínica habitual es la angiografía por tomografía de coherencia óptica (OCT-A), la cual ofrece imágenes de alta calidad de la circulación retiniana sin necesidad de contraste, permitiendo un examen preciso de la red vascular del ojo a distintas profundidades. Así pues, esta técnica encuentra su máxima utilidad en el diagnóstico de la DMAE húmeda, no la seca.

Inteligencia Artificial y *Deep Learning*

La inteligencia artificial consiste en un programa informático capacitado para resolver un problema determinado. Este campo de estudio se inició en los años 50 y se ha ido desarrollando de forma progresiva hasta experimentar un boom exponencial en los últimos 10 años, facilitado por el desarrollo paralelo de una maquinaria informática cada vez más potente capaz de realizar cálculos más complejos en un tiempo cada vez menor. Existen 2 tipos de IA:

- **Débil o estrecha:** inteligencia limitada con capacidad para realizar tareas específicas predeterminadas.
- **Fuerte o general:** inteligencia “ilimitada o consciente” con capacidad para realizar cualquier tarea de forma general, igualando o incluso excediendo la inteligencia humana promedio.

En la actualidad, todos los sistemas de IA existentes son muestras de IA débil, puesto que cada programa se diseña con el objetivo específico de realizar una única tarea. Hasta el momento, no existe ninguna máquina que posea la capacidad de pensar por sí misma o de resolver múltiples tareas en distintos ámbitos.

Por su lado, el aprendizaje de máquinas o *machine learning* podría considerarse como un hito dentro del campo de la IA. El desarrollo de esta técnica ha permitido que un programa diseñado para resolver una tarea determinada aprenda de la experiencia con la finalidad de perfeccionar su desempeño en dicha tarea. En el caso del aprendizaje profundo o *deep learning*, existe además la posibilidad de inferir predicciones futuras en estas tareas.

Redes neurales

Los sistemas informáticos basados en IA se diseñan con una estructura que intenta simular las sinapsis neuronales, conocidas como **redes neurales**. Estas redes están formadas por un gran número de **neuronas artificiales** (Figura 4) altamente interconectadas, que procesan información de forma dinámica en respuesta a los estímulos externos. Así, de forma análoga, el programa intenta procesar la decisión de la tarea encomendada a partir de comenzar el circuito por un extremo (“*input*”) y pasar por distintas capas hasta obtener un resultado (“*output*”) (Figura 5).

Las entradas o “*inputs*” pueden ser entradas a la red desde el exterior o bien proceder de otras neuronas. Del mismo modo, las salidas o “*outputs*” pueden funcionar como señal de salida de la red o bien transmitirse a otras neuronas. Las señales de entrada que recibe cada neurona artificial están moduladas por un factor conocido como “peso”, el cual regula la relevancia de la conexión existente entre el emisor de la señal y la neurona receptora.

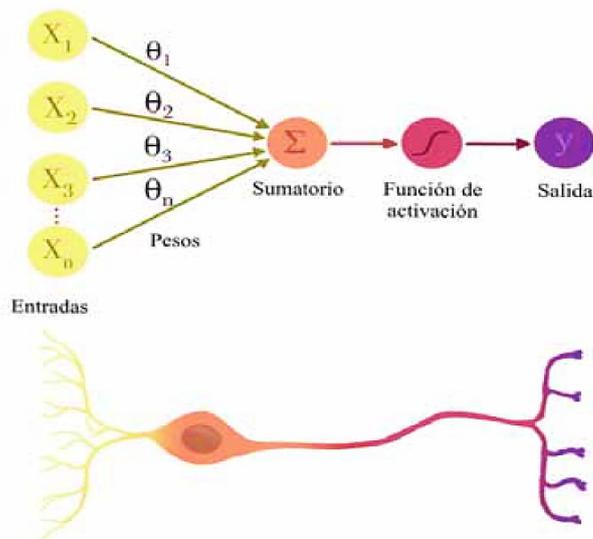


Figura 4. Neurona artificial. Fuente: Inteligencia Artificial en Retina. Monografía (SERV)¹.

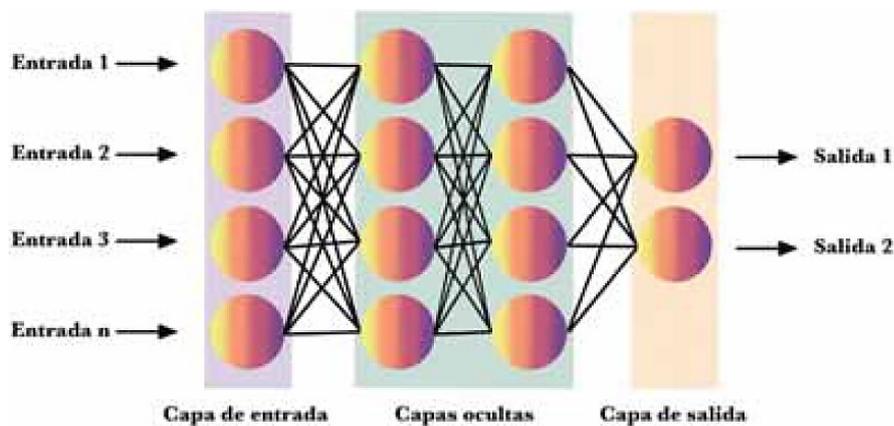


Figura 5. Redes neurales. Fuente: Inteligencia Artificial en Retina. Monografía (SERV)¹.

El procesamiento que realiza cada neurona se basa en la suma ponderada de sus entradas –teniendo en cuenta el peso asignado a cada una– y al resultado de esa suma se le aplica una “función de activación”. En esencia, si se supera un umbral preestablecido se produce como salida un valor cercano o igual a 1, lo que supone la “activación” de esa neurona; en su defecto, un valor cercano o igual a 0 mantiene la neurona “inactiva”. En términos generales, la activación de las neuronas hasta la capa de salida supone la realización de la tarea encomendada.

Aplicaciones en Salud y Oftalmología

La IA ya ha sido ampliamente utilizada en otros campos pero apenas empieza a impactar en el área de la Salud. En el caso de la oftalmología, esta ha sido siempre considerada como una especialidad médica pionera en el desarrollo e introducción de la tecnología moderna en la práctica clínica diaria.

Los métodos quirúrgicos actuales difieren significativamente de los empleados hace 20 años. Del mismo modo, las técnicas de imagen diagnósticas también han experimentado una considerable mejoría, como con la aparición de la tomografía de coherencia óptica, la cual ha proporcionado un importante avance en el conocimiento estructural de la retina, llegando incluso a la obtención de imágenes de campo amplio y evaluaciones del flujo sanguíneo.

La aparición de estas técnicas ha permitido la obtención de grandes volúmenes de datos explotables en beneficio del paciente. Además, en paralelo a este desarrollo, la llegada de la IA ha demostrado una prometedora capacidad de sus algoritmos de ver más allá de lo que los humanos pueden ver en las imágenes, permitiendo incluso mostrar asociaciones entre estas y otros datos clínicos de interés.

La IA ha adquirido un papel importante dentro de esta especialidad, pero el DL ha encontrado su máxima utilidad en un campo en particular: el reconocimiento de imágenes. En concreto, se ha aplicado principalmente en el estudio de imágenes de retinografías y de OCT. Gracias a ello, la IA ha permitido un desempeño excelente en la detección de diversas patologías, entre las que destacan la retinopatía diabética y de la prematuridad, el glaucoma, el edema macular y la degeneración macular asociada a la edad, enfermedad en la cual se centra esta revisión.

Además, el DL aplicado a la imagen ocular también puede utilizarse en conjunto con la telemedicina constituyendo una propuesta viable de cribado, diagnóstico y monitorización de las principales enfermedades oculares tanto a nivel de atención primaria como en la comunidad en general.

Reconocimiento de imágenes

Los sistemas informáticos basados en inteligencia artificial pueden aplicar diversas modalidades a sus algoritmos, pero en el campo del reconocimiento de imágenes existe una, más extendida, que resulta especialmente útil.

En resumen, para configurar un sistema automático capaz de clasificar imágenes en función de unas características de interés preestablecidas son necesarios dos elementos fundamentales: un conjunto de datos etiquetados y unos algoritmos que manipulen esos datos, más específicamente una arquitectura de red de convolución profunda que sea capaz de considerar como *input* una imagen y ofrecer como *output* la clasificación de dicha imagen (Figura 6).

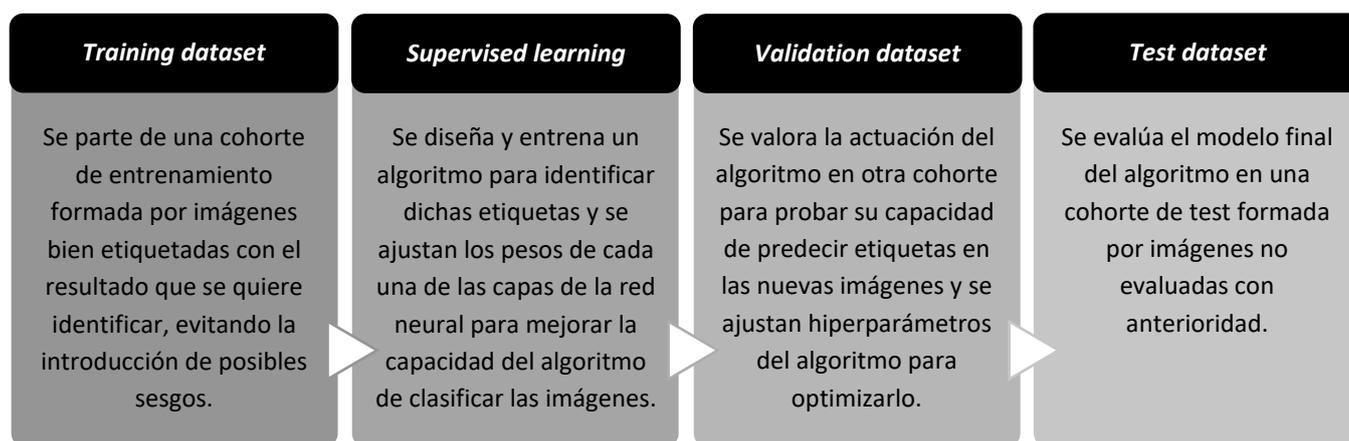


Figura 6. Esquema general del proceso de reconocimiento de imágenes mediante IA. Fuente: elaboración propia.

Este modelo conforma un sistema de aprendizaje basado en ejemplos. En el caso que nos ocupa, su utilidad radica en la posibilidad de analizar imágenes diagnósticas (retinografías, OCT) para su clasificación o etiquetaje en función del estadio de DMAE existente, entre otras finalidades.

Actualmente, dado el notable auge de la tecnología que cimienta las redes de convolución profunda, han aparecido diversas arquitecturas prometedoras que ya constituyen un estándar a la hora de abordar problemas en el campo del reconocimiento de imágenes; algunos ejemplos son: VGG16, ResNET50, Inception, Xception...

Una vez diseñada la arquitectura de la red, partiendo de alguna de las arquitecturas preexistentes o bien partiendo de cero si la naturaleza del problema así lo requiere, se procede a su implementación mediante alguno de los *frameworks* de desarrollo disponibles.

Al igual que con las arquitecturas, también hay disponibles diversos *frameworks* que permiten la implementación rápida y cómoda de esta tecnología. Destaca el *framework* TensorFlow, puesto al servicio de la comunidad de la mano de Google, considerado el estándar de desarrollo en lo que a *deep learning* se refiere, ya que provee las herramientas necesarias para diseñar, construir, entrenar, validar y poner en marcha cualquier sistema basado en redes de convolución profunda.

HIPÓTESIS Y OBJETIVOS

La introducción de la inteligencia artificial en el campo de la medicina y particularmente en oftalmología constituye una innovación tecnológica prometedora que en un futuro próximo estará cada vez más presente en la profesión.

Hipótesis

1. La IA aplicada al procesamiento de imágenes en el **cribado de DMAE seca** lo convierte en una práctica más accesible, rápida y eficiente.
2. La IA aplicada al procesamiento de imágenes en el **diagnóstico de DMAE seca** proporciona una mayor sensibilidad frente al modelo clásico de interpretación clínica por parte de especialistas.
3. La IA aplicada al procesamiento de imágenes en el **pronóstico de DMAE seca** ayuda a predecir el riesgo de progresión y severidad, pudiendo los pacientes beneficiarse de un tratamiento médico más temprano para salvar su visión, mejorando su pronóstico.
4. La IA aplicada al procesamiento de imágenes en el **seguimiento de DMAE seca** lo convierte en una práctica más accesible, permitiendo una monitorización por telemedicina más precisa y un abordaje más individualizado, además de disminuir la carga de las visitas para los pacientes y el personal sanitario.

Objetivos

El objetivo principal de este trabajo consiste en realizar una detallada revisión bibliográfica para dar respuesta a las hipótesis planteadas, así como también proporcionar un resumen de la situación actual ("*state-of-the-art*") de los diferentes sistemas de IA utilizados en DMAE, entre otros:

OBJETIVO PRINCIPAL

- **Valorar la utilidad de la IA en el cribado, diagnóstico, pronóstico y seguimiento de la DMAE seca.**

OBJETIVOS SECUNDARIOS

- Ofrecer nociones básicas sobre los fundamentos de la IA.
- Proporcionar un resumen del estado de arte de los sistemas de IA utilizados en DMAE.
- Comentar los potenciales retos existentes para completar la translación de estas técnicas de computación a la práctica clínica diaria.

METODOLOGÍA

El diseño de este trabajo consta de dos partes principales: una primera parte de **revisión bibliográfica** con el fin de establecer el estado de arte del tema, y una segunda parte con el **proceso de investigación** realizado a partir de la bibliografía disponible para intentar dar respuesta a las hipótesis planteadas.

Primera parte: revisión bibliográfica

Búsqueda de literatura

La búsqueda de literatura se ha llevado a cabo utilizando tres métodos. El primero, más sencillo, ha consistido en una búsqueda genérica de información teórica de utilidad en los grandes motores de búsqueda vía Internet. Esto ha permitido el acceso a fuentes de información importantes como la Sociedad Española de Vitreo y Retina o la Organización Mundial de la Salud.

El segundo método, que ha facilitado la elaboración de la mayor parte del trabajo, ha consistido en la búsqueda de bibliografía científica específica mediante la base de datos de PubMed. Dado que el objetivo principal de esta revisión consiste en analizar la implicación de la IA en el cribado, diagnóstico, pronóstico y seguimiento de la DMAE seca, se han diseñado las siguientes estrategias de búsqueda avanzada:

- **ESTRATEGIA A:** (((Diagnosis[MeSH Terms]) OR (Vision Screening[MeSH Terms])) AND (Artificial Intelligence[MeSH Terms])) AND (Macular Degeneration[MeSH Terms]). Esta estrategia se centra en la búsqueda de artículos relacionados con el diagnóstico o cribado de la DMAE en el campo de la IA.
- **ESTRATEGIA B:** (((Prognosis[MeSH Terms]) OR (Treatment[MeSH Terms])) AND (Artificial Intelligence[MeSH Terms])) AND (Macular Degeneration[MeSH Terms]). Esta estrategia se centra en la búsqueda de artículos relacionados con el pronóstico o tratamiento de la DMAE en el campo de la IA.
- **ESTRATEGIA C:** (((Follow-up[MeSH Terms]) OR (Monitoring[MeSH Terms])) AND (Artificial Intelligence[MeSH Terms])) AND (Macular Degeneration[MeSH Terms]). Esta estrategia se centra en la búsqueda de los artículos relacionados con el seguimiento de la DMAE en el campo de la IA.

Por último, también se ha consultado parte de la literatura indexada en las referencias bibliográficas de los artículos estudiados de mayor interés.

Selección de estudios

Dado que la temática de la revisión bibliográfica es relativamente amplia, los criterios de inclusión han sido “laxos”, incluyendo para su estudio los artículos que, formando parte de los resultados de la búsqueda avanzada expuesta, cumpliesen los criterios de inclusión siguientes: (1) **estudios con una definición clara de DMAE**; (2) **estudios con información sobre la base de datos y el número de imágenes utilizadas**; (3) **estudios con información sobre índices de evaluación como sensibilidad, especificidad, precisión y área bajo la curva**; (4) **estudios con información sobre los algoritmos y procedimientos utilizados en la detección de la DMAE**; (5) **estudios con información acerca del estándar de referencia utilizado**; y (6) **estudios con fecha de publicación inferior a los 5 años**. En cuanto a criterios de exclusión, ha habido uno y ha sido el siguiente: **estudios centrados en DMAE de tipo exudativa o neovascular**.

Se han examinado individualmente los artículos disponibles y seleccionado los de mayor interés para la revisión.

Segunda parte: proceso de investigación

Extracción de datos

Se han recopilado los siguientes datos a partir de los estudios seleccionados: (1) **características básicas de los estudios** e (2) **índices de evaluación de los algoritmos utilizados**.

Análisis estadístico

Para analizar los datos obtenidos se ha procedido a la lectura de los estudios con la finalidad de determinar qué pruebas diagnósticas posibilitan un mayor rendimiento de la IA en cuanto a cribado, diagnóstico, pronóstico y seguimiento de la DMAE, a fin de permitir la creación de un esquema básico que recopile esta información y sea accesible para oftalmólogos u otros colectivos interesados.

Para ello, se ha dividido el análisis de los artículos y sus resultados en tres categorías según la utilidad potencial de la IA en los distintos ámbitos de interés: (1) IA en el cribado y diagnóstico de la DMAE; (2) IA en el pronóstico y tratamiento de la DMAE e (3) IA en el seguimiento y monitorización domiciliar de la DMAE.

Para la comparación de los modelos de IA aplicados a distintas imágenes en cada estudio se han utilizado los índices de evaluación facilitados, sobre todo los valores de precisión y de área bajo la curva, procedentes de las curvas de características operativas del receptor (ROC). Por su lado, los valores de precisión se han definido como el número total de imágenes correctamente etiquetadas respecto al total de estudiadas ($((VP^1 + VN^2) / (VP + VN + FP^3 + FN^4))$).

¹ VP: verdaderos positivos.

² VN: verdaderos negativos.

³ FP: falsos positivos.

⁴ FN: falsos negativos.

RESULTADOS

Las diferentes estrategias de búsqueda utilizadas para estudiar el estado de arte del tema han proporcionado la cantidad siguiente de artículos:

- **ESTRATEGIA A:** 115 resultados a día 16 de enero de 2021.
- **ESTRATEGIA B:** 17 resultados a día 16 de enero de 2021.
- **ESTRATEGIA C:** 0 resultados a día 16 de enero de 2021.

Ha sido difícil conformar un repertorio de artículos que trabajaran exactamente lo que se quería investigar, pues muchos de los artículos encontrados abordaban la utilización de la inteligencia artificial en los distintos ámbitos de interés pero sobre otras patologías, principalmente la retinopatía diabética, que es la enfermedad que cuenta con el mayor soporte bibliográfico en relación con esta tecnología.

No obstante, se ha llevado a cabo una minuciosa selección de los artículos más significativos para su estudio y con ellos se han establecido las tres categorías de análisis comentadas en el apartado anterior. Así, de los 122 artículos potencialmente elegibles para su inclusión al inicio, después de la selección primaria y la revisión del texto completo se han reducido a un total de 28 revisados, posteriormente divididos en las tres categorías de estudio (Figura 7).

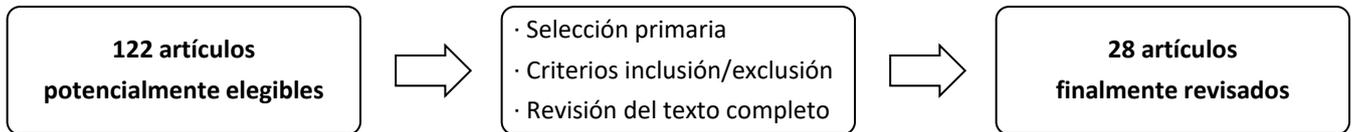


Figura 7. Revisión bibliográfica: selección de estudios. Fuente: elaboración propia.

De este modo, la revisión bibliográfica ha trabajado finalmente con la cantidad siguiente de artículos:

1. **IA en el cribado y diagnóstico de la DMAE:** 20 artículos.
2. **IA en el pronóstico y tratamiento de la DMAE:** 6 artículos.
3. **IA en el seguimiento y monitorización domiciliar de la DMAE:** 2 artículos.

1. IA en el cribado y diagnóstico de la DMAE

IA en el procesamiento de imágenes de retinografía

La retinografía o fotografía del fondo de ojo es una técnica fotográfica nacida a mediados del siglo XIX de bajo coste, fácil acceso e inocua, hecho que la ha convertido en una prueba de gran implementación a la vez que básica en la práctica clínica diaria oftalmológica. En este contexto, la aplicación del análisis automatizado de las retinografías mediante inteligencia artificial constituye una revolución en el cribado y diagnóstico de las patologías retinianas.

Los elementos básicos que se tienen en cuenta para la identificación de la DMAE tanto por parte de los oftalmólogos como de los algoritmos que reconocen las retinografías, son principalmente las drusas presentes a nivel del epitelio pigmentario, así como la posible presencia de anomalías pigmentarias o de neovasos. Así, son estas características las que se persigue detectar mediante los algoritmos con el fin de emitir un etiquetaje adecuado de la patología.

En el caso de la DMAE, existen numerosos estudios que evalúan el rendimiento de la IA en el reconocimiento de retinografías para su cribado y diagnóstico (Tabla 3), mostrando en su totalidad resultados de rendimiento muy elevados comparables e incluso en ocasiones superiores a los estándares de referencia, que suelen consistir en la evaluación de las mismas imágenes por parte de oftalmólogos u otros especialistas expertos.

Primer autor	Fecha de publicación	País	Base de datos	Imágenes totales	Metodología	Resultado	Clasificación	Rendimiento
Burlina ⁶	2017 Mar	Estados Unidos	AREDS	5.664	CNN	DMAE I/A	1. Enfermedad/ no enfermedad 2. Severidad DMAE (4 clases)	ACC ₁ : 0,934 ACC ₂ : 0,794
Kunumpol ⁷	2017 Jul	Tailandia	STARE	106	ANN	DMAE	Enfermedad/ no enfermedad	ACC: 0,989
Burlina ⁸	2017 Nov	Estados Unidos	AREDS	133.821	CNN	DMAE I/A	Enfermedad/ no enfermedad	ACC: 0,916 AUC: 0,960
Ting ⁹	2017 Dec	Singapur	SIDRP	108.558	CNN	DMAE I/A	Enfermedad/ no enfermedad	ACC: 0,888 AUC: 0,932
Govindaiah ¹⁰	2018 Jul	Estados Unidos	AREDS	116.875	CNN	1. DMAE I/A 2. DMAE	1. Enfermedad/ no enfermedad 2. Severidad DMAE (4 clases)	ACC ₁ : 0,953 ACC ₂ : 0,861
Grassmann ¹¹	2018 Sep	Alemania	AREDS	120.656	CNN	DMAE	Severidad DMAE (13 clases)	ACC: 0,633
Peng ¹²	2019 Apr	Estados Unidos	AREDS	59.302	CNN	DMAE	Severidad DMAE (6 clases)	ACC: 0,671
Keenan ¹³	2019 Nov	Estados Unidos	AREDS	59.812	CNN	DMAE seca	Enfermedad/ no enfermedad	ACC: 0,965 AUC: 0,976
Zapata ¹⁴	2020 Feb	España	Optretina	306.302	CNN	DMAE	Enfermedad/ no enfermedad	ACC: 0,863 AUC: 0,936
Bhuiyan ¹⁵	2020 Apr	Estados Unidos	AREDS	116.875	CNN	1. DMAE I/A 2. DMAE	1. Enfermedad/ no enfermedad 2. Severidad DMAE (4 clases)	ACC ₁ : 0,992 ACC ₂ : 0,961
González-Gonzalo ¹⁶	2020 Jun	Países Bajos	1. DR...-AMD 2. AREDS	134.421	CNN	DMAE I/A	Enfermedad/ no enfermedad	ACC ₁ : 0,880 AUC ₁ : 0,949 ACC ₂ : 0,859 AUC ₂ : 0,927

AREDS: Age-Related Eye Disease Study; CNN: convolucional neural network; DMAE I/A: intermedia o avanzada; ACC: accuracy (precisión); AUC: area under curve; STARE: Structured Analysis of the Retina; ANN: artificial neural network; SIDRP: Singapore National Diabetic Retinopathy Screening Program.

Tabla 3. Información de estudios sobre diagnóstico de DMAE por retinografías con IA. Fuente: elaboración propia.

En la mayoría de estudios este rendimiento se refleja mediante valores de precisión (“ACC: accuracy”) y/o valores de área bajo la curva (“AUC: area under curve”) obtenidos a partir de curvas de características operativas del receptor (ROC), encontrándose todos ellos muy cercanos al 1 (Tabla 8), lo que significa que el test estudiado –es decir, el reconocimiento de retinografías por IA– ofrece una muy buena capacidad de discriminación de la DMAE.

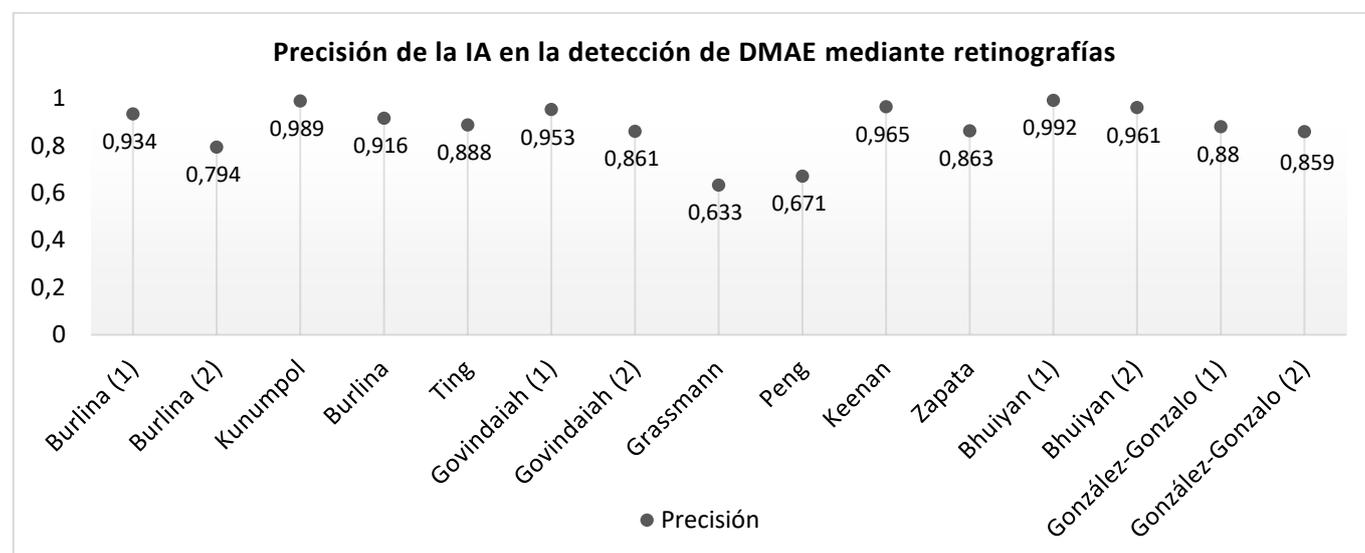


Figura 8. Precisión de los algoritmos de IA en la detección de DMAE mediante retinografías. Fuente: elaboración propia.

IA en el procesamiento de imágenes de Tomografía de Coherencia Óptica (OCT)

La Tomografía de Coherencia Óptica (OCT) es una técnica de imagen no invasiva surgida en el año 1995 que emplea un emisor de luz infrarroja y aprovecha un principio óptico (la interferometría) con la finalidad de obtener imágenes o cortes a una resolución muy elevada, similar a la obtenida en cortes microscópicos de la retina.

En el caso de la OCT, los signos considerados para la identificación de DMAE por parte de los algoritmos de IA son los mismos que en las retinografías. Sin embargo, en el procesamiento de este tipo de imágenes lo que varía es la modalidad en la que estos algoritmos reconocen dichos signos.

En términos generales, para identificar signos de DMAE en una OCT se suele realizar una segmentación de las capas de la retina para establecer las etiquetas de lo que se persigue reconocer en cada capa por parte del algoritmo, que en el caso de la DMAE son esencialmente las drusas que desplazan y deforman el EPR (Figuras 9 y 10).

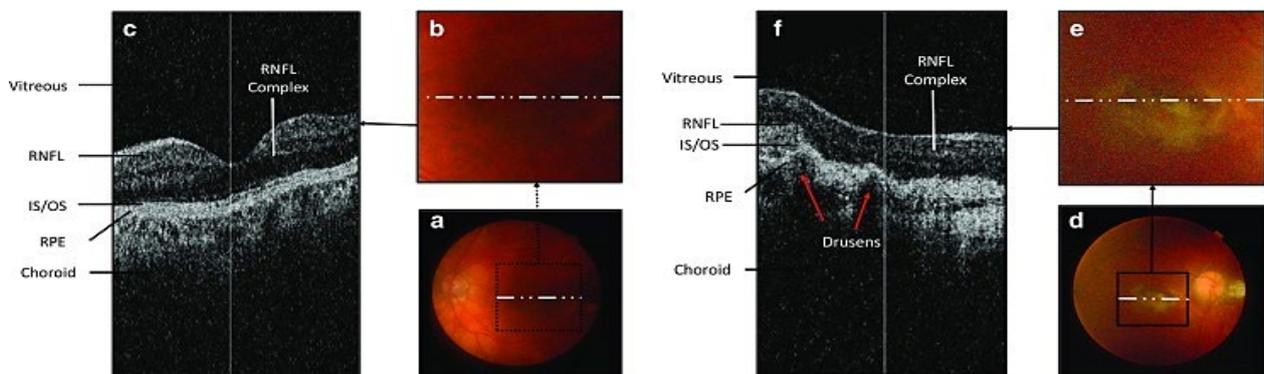


Figura 9. (a) Imagen de fondo de ojo de una retina normal. El cuadrado negro representa la región macular de la retina normal, cuya patología transversal se presenta en (c); (c) exploración SD-OCT B dirigida por la línea punteada blanca en (b); (d) imagen de fondo de ojo de una retina afectada por DMAE. El cuadrado negro representa la región macular de la retina con DMAE, cuya patología transversal se presenta en (f); (f) exploración SD-OCT B dirigida por la línea punteada blanca en (d). Fuente: Khalid et al.¹⁹ (2018).

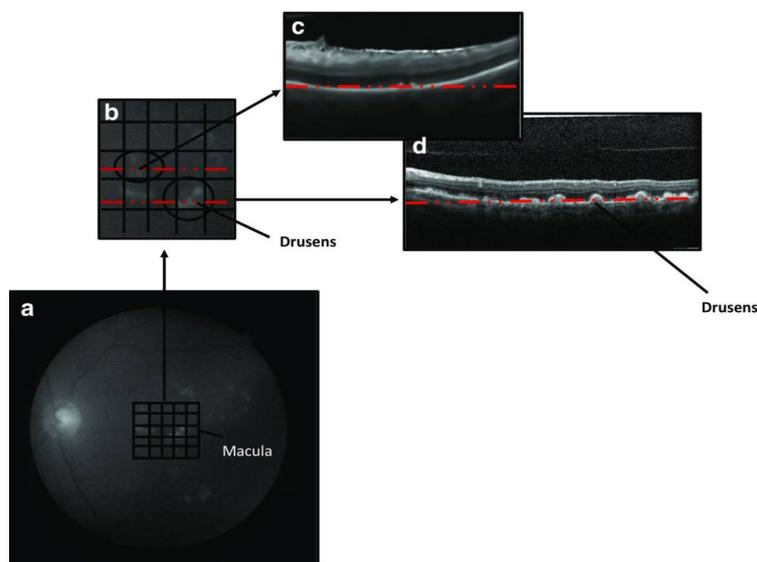


Figura 10. (a) Imagen de fondo de ojo de una retina afectada por DMAE; (b) región macular de (a) que representa la patología de las drusas; (c) exploración SD-OCT del área de forma ovalada en (b), la línea discontinua roja indica la ubicación en (b) de la imagen presentada, que muestra alguna drusa pequeña; (d) exploración SD-OCT del área de forma ovalada en (b), la línea discontinua roja indica la ubicación en (b) de la imagen presentada, que muestra varias drusas pequeñas. Fuente: Khalid et al.¹⁹ (2018).

Muchos investigadores han trabajado en la detección de DMAE a partir de retinografías en color, pero son pocos los estudios al respecto a partir de imágenes de OCT (Tabla 4). No obstante, ambas pruebas son complementarias y podría establecerse una correspondencia entre ellas para apoyar la toma de decisiones respecto esta enfermedad.

Primer autor	Fecha de publicación	País	Base de datos	Imágenes totales	Metodología	Resultado	Clasificación	Rendimiento
Lee ¹⁸	2017 Jul	Estados Unidos	–	101.002	CNN	DMAE	Enfermedad/ no enfermedad	ACC: 0,876 AUC: 0,928
Khalid ¹⁹	2018 Aug	Pakistán	AFIO	6.800	–	DMAE	1. Enfermedad/ no enfermedad 2. Severidad DMAE (3 clases)	ACC ₁ : 0,964 ACC ₂ : –
Hwang ²⁰	2019 Jan	Taiwán	TVGH	23.342	CNN (3 modelos)	DMAE	Severidad DMAE (4 clases)	ACC ₁ : 0,914 ACC ₂ : 0,927 ACC ₃ : 0,907
Yoo ²¹	2019 Mar	Corea del Sur	Project Macula	–	CNN	DMAE	Enfermedad/ no enfermedad	ACC: 0,826 AUC: 0,906
Saha ²²	2019 Jul	Estados Unidos	Doheny Eye Centers	19.584	CNN	DMAE	Enfermedad/ no enfermedad	ACC: 0,870
Ann ²³	2019 Jul	Japón	–	1.625	CNN	DMAE	1. Enfermedad/ no enfermedad 2. Severidad DMAE (2 clases)	ACC ₁ : 0,992 AUC ₁ : 0,999 ACC ₂ : 0,951 AUC ₂ : 0,992
Motozawa ²⁴	2019 Dec	Japón	KCMCGH	1.621	CNN	DMAE	1. Enfermedad/ no enfermedad 2. Severidad DMAE (2 clases)	ACC ₁ : 0,990 AUC ₁ : 0,995 ACC ₂ : 0,939 AUC ₂ : 0,991

AFIO: Instituto de Oftalmología de las Fuerzas Armadas; TVGH: Taipei Veterans General Hospital; KCMCGH: Kobe City Medical Center General Hospital.

Tabla 4. Información de estudios sobre diagnóstico de DMAE por OCT con IA. Fuente: elaboración propia.

Del mismo modo que en los estudios con retinografías, el rendimiento de la IA en el reconocimiento de OCT para el cribado y diagnóstico de DMAE también se refleja mediante valores de precisión y/o valores de área bajo la curva, todos ellos mayores de 0,8 evidenciando la gran capacidad de discriminación de este método (Figura 11).

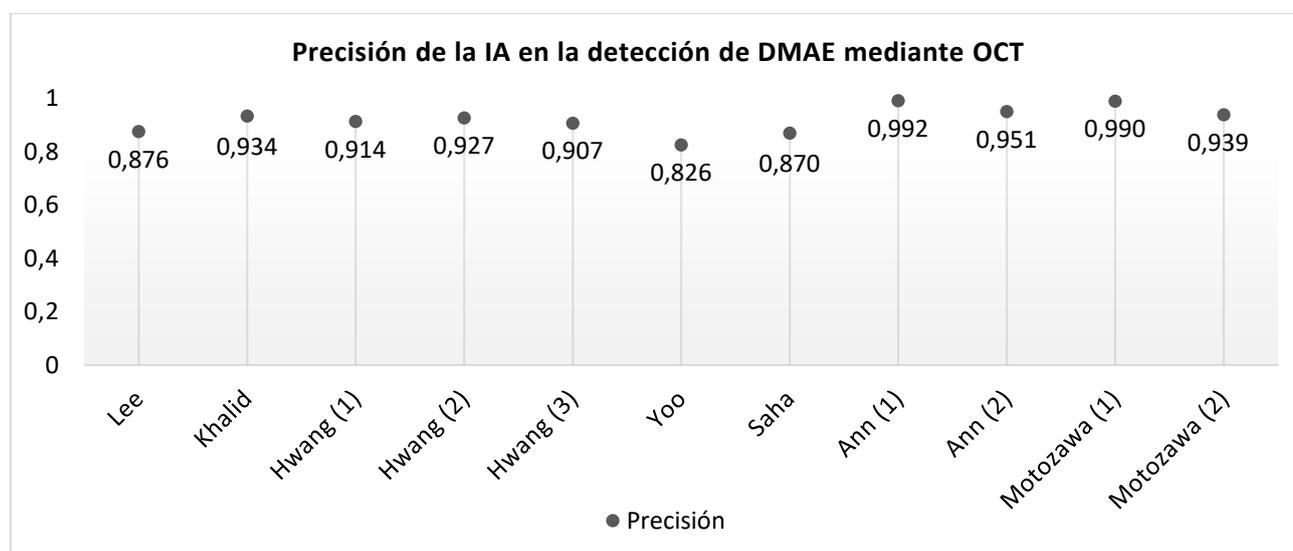


Figura 11. Precisión de los algoritmos de IA en la detección de DMAE mediante OCT. Fuente: elaboración propia.

IA en el procesamiento de imágenes de OCT angiográfica (OCT-A)

La OCT angiográfica es una técnica novedosa y aún no del todo extendida en la práctica clínica habitual, por lo que será necesaria su instauración en muchas más unidades de oftalmología antes de poder evaluar con fiabilidad la utilidad de aplicar la IA en el reconocimiento de estas imágenes.

Vaghefi et al.²⁵ (2020) entrenaron una red neuronal convolucional profunda con OCT, que mostró una precisión del 94%, mientras que la red entrenada con imágenes de OCT-A mostró una precisión del 91%. Cuando se combinaron ambas modalidades, la precisión de la red aumentó al 96% en la cohorte de DMAE.

IA en el procesamiento de imágenes de autofluorescencia

La autofluorescencia (AF) es la emisión de luz por parte de componentes tisulares de origen natural al absorber la luz incidente. Este fenómeno a nivel intraocular se asocia con varios trastornos, siendo uno de ellos la DMAE.

Pese a que la fisiopatología implicada en el desarrollo de la DMAE sigue sin ser comprendida del todo, se sabe que el EPR es una de las estructuras celulares más dañadas en esta enfermedad. Además, la acumulación de depósitos subepiteliales que conforman las drusas, los depósitos lineales y los depósitos laminares basales, parecen estar constituidos por sustancias con cierta actividad autofluorescente, por lo que la AF no solo aporta información a nivel anatómico (como la angiografía fluoresceínica) sino también desde un punto de vista funcional.

Bindewald et al.²⁶ (2005) distinguieron hasta ocho fenotipos diferentes objetivables en la AF de pacientes con DMAE incipiente. Actualmente, la correlación entre los hallazgos en la AF del fondo de ojo y las posibilidades de progresión a DMAE exudativa es objeto de numerosos estudios. Sin embargo, los resultados hasta día de hoy parecen ser contradictorios, por lo que serán necesarios futuros estudios para aportar un poco más de luz al respecto.

En esta línea, apenas existe bibliografía disponible acerca de la aplicación de la IA en el reconocimiento de imágenes de AF (Tabla 5). Treder et al.²⁷ (2018) entrenaron una red neuronal convolucional profunda con estas imágenes para detectar automáticamente la atrofia geográfica característica de la DMAE y diferenciar entre distintos patrones, con unos resultados de rendimiento excelentes. Aun así, sigue siendo necesaria más investigación en esta dirección.

Primer autor	Fecha de publicación	País	Base de datos	Imágenes totales	Metodología	Resultado	Clasificación	Rendimiento
Treder ²⁷	2018 Nov	Alemania	–	910	CNN	Atrofia geográfica	1. Enfermedad/ no enfermedad 2. Tipo atrofia (2 clases)	ACC ₁ : 0,960 ACC ₂ : 0,770

Tabla 5. Información de estudios sobre diagnóstico de DMAE por autofluorescencia con IA. Fuente: elaboración propia.

IA en el procesamiento de imágenes de angiografía fluoresceínica

En el caso de otro tipo de pruebas de imagen relacionadas con el diagnóstico de la DMAE, como es la angiografía fluoresceínica, no se ha encontrado bibliografía disponible acerca de la aplicación de la IA en su reconocimiento.

2. IA en el pronóstico y tratamiento de la DMAE

Si bien millones de personas muestran signos de DMAE temprana pero tienen una visión excelente, el riesgo de progresión a DMAE avanzada con ceguera legal es muy variable. Se han sugerido algunos sistemas de IA, todos ellos basados en imágenes de OCT, las cuales son más sensibles, para predecir individualmente el riesgo de progresión de la DMAE hacia un estadio avanzado ya sea con atrofia geográfica o con neovascularización (Tabla 6).

Primer autor	Fecha de publicación	País	Base de datos	Imágenes totales	Metodología	Resultado	Clasificación	Rendimiento
Schmidt-Erfurth ²⁸	2018 Jul	Austria	–	–	CNN	DMAE avanzada	1. Progresión a AG / no progresión 2. Progresión a NVC / no progresión	ACC ₁ : 0,680 ACC ₂ : 0,800
Russakoff ²⁹	2019 Feb	Reino Unido	–	–	CNN	DMAE exudativa	Progresión / no progresión	AUC ₁ : 0,910 AUC ₂ : 0,870
Waldstein ³⁰	2020 Jul	Austria	Estudio HARBOR	8.529	CNN	DMAE avanzada	Progresión a AG o NVC / no progresión	–
Waldstein ³¹	2020 Jul	Austria	Ensayo clínico*	54.900	CNN	DMAE avanzada	Progresión a AG o NVC / no progresión	–

Schmidt-Erfurth ³²	2020 Aug	Austria	–	491	RNN	DMAE atrófica	Progresión / no progresión	–
Banerjee ³³	2020 Sep	Estados Unidos	–	13.954	RNN	DMAE exudativa en 3 m	Progresión / no progresión	AUC: 0,960

AG: atrofia geográfica; NVC: neovascularización; *Ensayo clínico aleatorizado registrado en Clinicaltrials.gov con el identificador “NCT00891735”; RNN: recursive neural network.

Tabla 6. Información de estudios sobre pronóstico de DMAE con IA. Fuente: elaboración propia.

Los biomarcadores críticos para predecir el riesgo de progresión de DMAE, tomados en cuenta por la mayor parte de estudios, son principalmente el grosor retiniano externo, el área de las drusas y los focos hiperreflectantes. Además, estos estudios han demostrado que estas características cuantitativas siguen patrones patognomónicos claramente diferentes para las vías atrófica y neovascular. De este modo, los sellos predictivos de la progresión atrófica se asocian con la retina neurosensorial y la edad, mientras que los marcadores de progresión neovascular se centran sobre todo en el tamaño de las drusas.

Los resultados de los estudios han sido buenos en todos los casos, superando la variabilidad entre observadores en las predicciones de expertos y demostrando el potencial del uso de la IA para predecir la progresión de la DMAE.

3. IA en el seguimiento y monitorización domiciliar de la DMAE

La elevada prevalencia de la DMAE así como su evidente tendencia creciente la convierten en una candidata idónea para las intervenciones de telesalud ocular. Diversos grupos han estudiado la viabilidad y validez de programas de telemedicina para esta enfermedad y cada vez son más los que intentan incluir en este campo los sistemas de IA. No obstante, la bibliografía disponible actualmente al respecto sigue siendo escasa.

Hwang et al.³⁵ (2019) presentaron una herramienta de interacción de telemedicina basada en IA y la nube para el diagnóstico y el tratamiento de la DMAE. A través de un proceso de aprendizaje profundo a partir del análisis de imágenes de OCT, el sistema propuesto logró la misma precisión que la de los especialistas en retina de su hospital y una precisión significativamente superior ($p < 0,001$) a la de los estudiantes de medicina. Además, proporcionó recomendaciones de tratamiento adecuadas comparables a las de los expertos.

Por otro lado, Nahen et al.³⁶ (2020) evaluaron un sistema de SD-OCT en investigación (Notal Vision Home OCT, NVHO) basado en IA para la obtención de imágenes a nivel domiciliar por parte de pacientes con DMAE exudativa para su comercialización. Los estudios de imagen realizados con NVHO fueron satisfactorios en todos los pacientes y el 95% de ellos calificó la operación del dispositivo para escanear sus propios ojos sin ayuda como fácil. Además, este sistema de OCT evaluado para uso doméstico cumple con todos los requisitos para la obtención de imágenes “auto-controladas” por pacientes con DMAE en lo que se refiere a calidad de imagen, campo de visión y usabilidad.

DISCUSIÓN

IA en el cribado y diagnóstico de la DMAE

A diferencia de la retinopatía diabética (RD), no existe un consenso sobre la utilidad del cribado de la DMAE a nivel poblacional. Algunos estudios han encontrado valor al agregar pruebas de detección de DMAE a los programas ya existentes de detección de RD, mientras que otros han determinado que no resulta rentable³⁴.

Una cosa sí está clara y es que el diagnóstico precoz de esta patología es esencial, pues el arsenal terapéutico del que se dispone permite frenar la pérdida de visión en los estadios iniciales. Así, una demora de un mes en el inicio del tratamiento después del diagnóstico conlleva una pérdida de visión en prácticamente la mitad de los pacientes.

La telemedicina incluida en Atención Primaria en el contexto de la puesta en marcha del Plan Integral de Diabetes ha permitido que la ceguera por retinopatía diabética haya disminuido considerablemente en los últimos años. En contraposición, la DMAE constituye un problema de salud cada vez más prevalente, siendo hoy en día la primera causa de ceguera a partir de los 50 años en los países desarrollados y una de las enfermedades que más recursos consume en nuestro Sistema Nacional de Salud. Por tanto, parece indudable el beneficio de implantar un sistema de cribado en los centros asistenciales para favorecer su diagnóstico precoz.

En lo que concierne esta revisión bibliográfica, existen estudios suficientes que demuestran que la aplicación de la IA en el reconocimiento de imágenes, principalmente de retinografías y OCT, muestra un rendimiento excelente a la hora de diagnosticar la DMAE y clasificarla en función de su severidad.

En cuanto a precisión diagnóstica, los resultados de los estudios analizados demuestran en su totalidad que el entrenamiento de una red con un número suficiente de imágenes funciona bien y es comparable a la clasificación por parte de especialistas en retina altamente capacitados, siendo en ocasiones incluso superior, sobre todo en el caso de las imágenes de OCT, las cuales de por sí mismas ya ofrecen una visión de la retina mucho más detallada.

No obstante, pese a los resultados excelentes de rendimiento a nivel general, estos varían visiblemente entre los distintos estudios incluidos, con precisiones que oscilan de 0,633 a 0,992 en el caso de las retinografías y de 0,826 a 0,992 en las OCT, hecho que puede explicarse por diversos factores. En primer lugar, las diferentes arquitecturas de algoritmos utilizadas en cada estudio son la causa básica de la variación de rendimiento. En segundo lugar, la cantidad de imágenes utilizadas para el entrenamiento y validación de los algoritmos es otra razón. En tercer lugar, la calidad de las imágenes utilizadas también puede tener un peso importante en esta variación. Por último, en el caso de los estudios con retinografías debe tenerse en cuenta que algunos de los matices para definir las drusas y otros cambios para la clasificación clínica de la DMAE según lo propuesto por Ferris et al. (2013) no existía en la década de 1980 durante AREDS, lo que podría implicar que esta base de datos sea inadecuada para desarrollar IA. Además, estas fotografías eran todas imágenes de películas que tuvieron que ser digitalizadas. Por este motivo, a la hora de comparar fiablemente los distintos sistemas de IA es necesaria una evaluación integral.

Si bien es cierto que existe una sutil superioridad en los resultados de precisión del procesamiento de imágenes de OCT frente a los de retinografías, estas últimas constituyen la herramienta más validada para la clasificación y predicción de progresión de la DMAE. Además, tienen la ventaja de ofrecer una mayor correlación con la biomicroscopia (a diferencia de las OCT) y de estar ampliamente disponibles (a diferencia de la autofluorescencia).

Por otro lado, los sistemas de IA necesarios para procesar imágenes de retinografías son mucho más sencillos que los necesarios para procesar imágenes tridimensionales complejas de OCT, los cuales pese a ser prometedores requieren unos softwares más sofisticados.

Pese a todo, la OCT también presenta ventajas importantes y es que estas imágenes proporcionan una visualización objetiva y confiable de la patología macular en etapas más tempranas, en particular la identificación y cuantificación de las drusas, lo que resulta fundamental en esta enfermedad, a diferencia de las retinografías que resultan más débiles para la localización y cuantificación temprana de las mismas.

Todas las características mencionadas respecto a los 2 tipos de imagen más utilizadas en el diagnóstico de la DMAE mediante IA, susceptibles de ser tomadas en cuenta para la utilización preferente de una u otra, se recogen en la siguiente tabla comparativa (Tabla 7).

	Retinografías	OCT
Precisión diagnóstica	Alta (++)	Alta (+++)
Sistema de IA requerido	Sencillo	Sofisticado
Detección DMAE temprana	Menor	Mayor
Correlación con biomicroscopia	Mayor	Menor
Disponibilidad en práctica clínica	Mayor	Menor
Coste	Menor	Mayor

Tabla 7. Comparativa entre retinografías y OCT para su procesamiento mediante IA en el diagnóstico de DMAE. Fuente: elaboración propia.

Varios estudios han demostrado que se puede lograr una precisión diagnóstica superior cuando el aprendizaje profundo se combina con un análisis de imágenes multimodales, frente a los modelos basados en redes entrenadas por una sola modalidad de imagen.

En definitiva, lo que resulta evidente es que a la hora de diagnosticar la DMAE mediante IA, independientemente de que la imagen procesada sea una retinografía, una OCT o ambas, a prácticamente “igualdad” de precisión, la IA ofrece una clara ventaja en cuanto a accesibilidad, rapidez y eficiencia frente a los modelos de interpretación por parte de los especialistas, al ser capaces estos algoritmos de procesar una mayor cantidad de imágenes en el mismo tiempo. El análisis conjunto de retinografías y OCT es la propuesta viable que ofrecería mejores resultados.

Sin embargo, conviene aclarar que, al menos hasta el momento, esta técnica no sería aplicable para el cribado en el ámbito de la atención primaria debido al coste mucho mayor de los dispositivos de OCT que el de las cámaras automáticas no midriáticas. Sería necesario un estudio de costo-efectividad o que la presencia de estos dispositivos se extienda más en las consultas de oftalmología.

En el caso de la autofluorescencia, se trata de una técnica exploratoria sencilla, rápida, barata, no invasiva y de fácil interpretación, en el estudio de la cual sería muy interesante profundizar. Sus amplias posibilidades de aplicación, aportando información complementaria en el diagnóstico, pronóstico y seguimiento de distintas enfermedades retinianas y por el resto de ventajas comentadas anteriormente, la convierten en una prueba prometedora y con claras opciones de generalizarse en el futuro próximo.

En el caso de otras técnicas de imagen como son la angiografía fluoresceínica y la OCT-A, sigue siendo necesario profundizar en su investigación en el contexto de la IA.

IA en el pronóstico y tratamiento de la DMAE

El análisis automatizado de biomarcadores en imágenes OCT mediante sistemas de IA permite predecir de forma personalizada la progresión de la DMAE. Además, algunos de estos biomarcadores son patognomónicos de cada vía, sugiriendo un riesgo de progresión al tipo atrófico o neovascular específicamente.

Se espera que aparezcan nuevos sistemas de aprendizaje profundo que abran las puertas a la detección de nuevos biomarcadores no visibles al ojo del médico, hecho que proporcionará un enfoque rápido, confiable y asequible para brindar una atención más individualizada, permitiendo una toma de decisiones más adecuada y objetiva.

IA en el seguimiento y monitorización domiciliar de la DMAE

Los pacientes con DMAE exudativa requieren visitas frecuentes a las consultas para identificar líquido en la retina que necesita tratamiento. Los exámenes frecuentes que utilizan la técnica de OCT representan una carga tanto para los pacientes como para sus cuidadores. El desarrollo de sistemas de IA que sean accesibles por los pacientes desde sus hogares brinda la oportunidad a una monitorización remota precisa y un abordaje individualizado mejorado, optimizando la gestión de esta patología tan prevalente.

La combinación de la nube, la telemedicina y los sistemas de IA para diagnosticar DMAE y dar recomendaciones de tratamiento ofrece una valiosa oportunidad a prácticas de salud inteligentes que puedan conducir a herramientas de diagnóstico precisas, atención al paciente más efectiva y una mejora en la calidad de vida.

Aunque estos sistemas pueden beneficiar tanto a pacientes como a médicos, acceder a ellos puede ser complicado si solo se encuentran disponibles a nivel de centros de investigación. Por eso, resultaría clave y un gran avance que los modelos eficaces de IA estuviesen al alcance del público por medio de alguna web en la nube fácil de usar.

Actualmente ya hay disponible públicamente algún modelo previamente entrenado y con buenos resultados, como por ejemplo DeepSeeNet (disponible en: <https://github.com/ncki-nlp/DeepSeeNet>) o el propuesto por Hwang et al.³⁵ (2019) (disponible en: <https://www.ym.edu.tw/~AI-OCT/>) (Figura 12). Sin embargo, hasta el momento no existe ningún sistema de IA autorizado por la FDA en relación con la DMAE, a diferencia de para la RD.

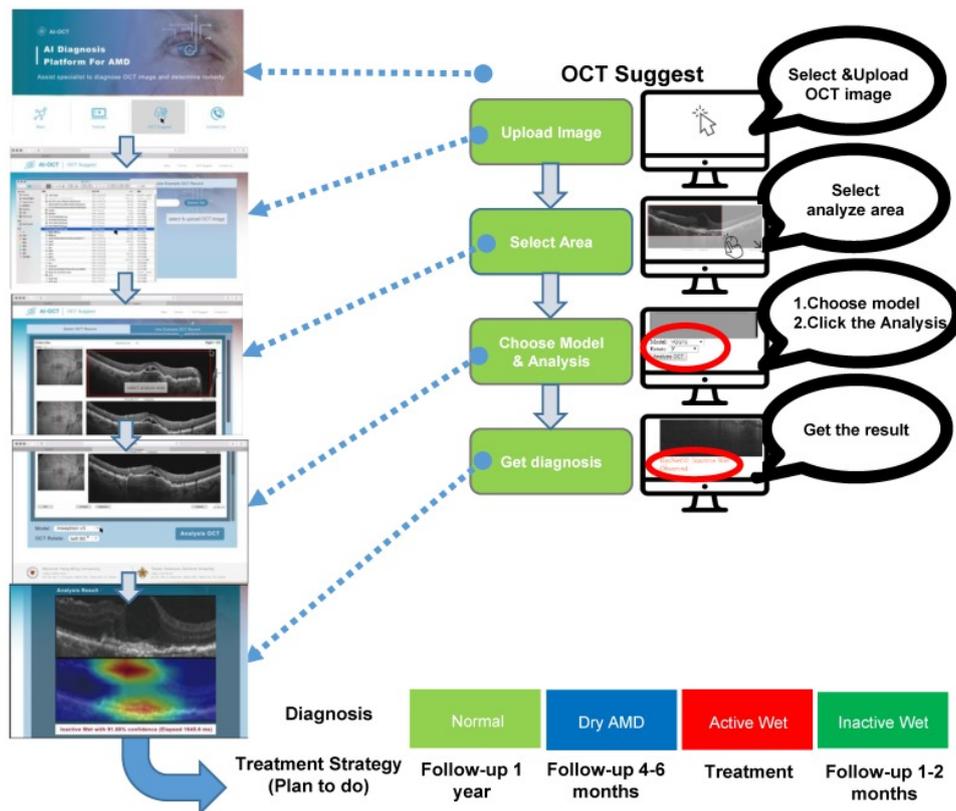


Figura 12. Esquema del interfaz y guía del usuario del software basado en IA-OCT en la nube. Fuente: Hwang et al.³⁵ (2019).

En 2018 la FDA autorizó el primer sistema de aprendizaje profundo para la detección automatizada de la RD para ser utilizado por proveedores de asistencia sanitaria. Esta organización preestableció valores determinados que debe alcanzar cualquier sistema para ser considerado lo suficientemente robusto para su traslado a un uso clínico (85% y 82,5% de sensibilidad y especificidad, respectivamente). Gran parte de los estudios analizados superan estos valores, por lo que es bastante posible que alguno de estos sistemas pueda ser aprobado próximamente.

A continuación se propone un resumen general de la utilidad de las distintas pruebas de imagen disponibles para el diagnóstico, pronóstico y seguimiento de la DMAE seca en el contexto de los sistemas de IA (Tabla 8).

	Retinografía	Autofluorescencia	Angiografía fluoresceínica	OCT	Angio-OCT
Diagnóstico	Alto	Media	Faltan estudios	Alto	Faltan estudios
Pronóstico	Media	Media	Faltan estudios	Alto	Faltan estudios
Seguimiento	Media	Faltan estudios	Faltan estudios	Alto	Faltan estudios

Tabla 8. Utilidad de distintas pruebas de imagen para el diagnóstico, pronóstico y seguimiento de DMAE seca mediante IA. Fuente: elaboración propia.

Limitaciones

A pesar de que todos los datos apuntan a que la aplicación de herramientas automáticas basadas en IA puede proporcionar beneficios sustanciales de cara al diagnóstico y pronóstico de la DMAE, también hay que tener en cuenta que el poder diagnóstico de estos algoritmos se ve disminuido al utilizarse en conjuntos mayores de datos, por lo que se requiere precaución a la hora de aplicarlos en una población más grande en condiciones distintas.

Además, el entrenamiento y prueba de los modelos de IA estudiados se llevan a cabo necesariamente en el contexto de prevalencias de DMAE elevadas, tratándose de ensayos clínicos controlados en lugar de escenarios del mundo real en un contexto realista de enfermedades y hallazgos de la retina. Por esto, antes del despliegue clínico, al igual que con cualquier otra prueba diagnóstica novedosa, se requiere una validación externa que debe realizarse en el entorno de uso previsto. Aun así, dado que la prevalencia de la DMAE es muy elevada y sigue en aumento, se espera que el desempeño de los modelos en la población sea similar a lo reportado en los estudios. Después de una demostración sólida de validez externa, este tipo de modelos estarán listos para su implementación con el fin de ayudar a los profesionales de la salud en entornos clínicos específicos.

Existe otro potencial reto en la implementación efectiva de estas tecnologías en la práctica diaria oftalmológica, como pueden ser las dificultades técnicas y la propia aceptación por parte tanto de los clínicos como de los pacientes, puesto que esto implicaría una modificación sustancial de los circuitos clínicos respecto a las vías habituales de atención a los pacientes. Aun así, no cabe duda de que en un futuro próximo tendrá lugar una revolución a nivel del cuidado de la salud ocular en este campo.

CONCLUSIONES

1. Es necesario considerar la implantación de un sistema de cribado para la degeneración macular asociada a la edad en los centros asistenciales con el fin de facilitar su diagnóstico precoz, esencial de cara a poder frenar la pérdida de visión durante los estadios iniciales, así como para disminuir la carga asistencial de las consultas de oftalmología.
2. La instauración de un sistema de cribado nacional para la DMAE se vería beneficiada por los sistemas de inteligencia artificial disponibles actualmente de cara a un rápido y preciso procesamiento de imágenes para su clasificación automática en función de la presencia o ausencia de enfermedad y su severidad.
3. La inteligencia artificial aplicada al procesamiento de imágenes en el diagnóstico de la DMAE seca, sobre todo de retinografías y OCT, ofrece resultados de precisión comparables o hasta en ocasiones superiores a los de la interpretación clínica por parte de especialistas altamente capacitados.
4. Puede lograrse una precisión diagnóstica superior de los modelos de aprendizaje profundo utilizados para el procesamiento de imágenes en el diagnóstico de la DMAE al combinar un análisis de imágenes multimodales, frente a los modelos basados en redes entrenados por una sola modalidad de imagen.
5. La autofluorescencia es una prueba sencilla, rápida, barata, no invasiva, de fácil interpretación y con amplias posibilidades de aplicación tanto en el diagnóstico, pronóstico como el seguimiento de distintas enfermedades de la retina, siendo una técnica exploratoria muy prometedora en el futuro próximo.
6. El análisis automatizado de biomarcadores en imágenes OCT mediante sistemas de IA, específicos de la vía de progresión atrófica o neovascular, permite predecir de forma personalizada el riesgo de progresión de la DMAE posibilitando un inicio mucho más precoz del tratamiento mejorando así el pronóstico.
7. El desarrollo de sistemas de IA accesibles por los pacientes desde sus hogares brinda la oportunidad a una monitorización remota precisa y un abordaje individualizado mejorado, optimizando la gestión de esta patología tan prevalente y disminuyendo la carga de las visitas para los pacientes, sus cuidadores y el propio personal sanitario.

AGRADECIMIENTOS

En primer lugar, me gustaría agradecer a Marc Baget su tutorización y la propuesta de este trabajo de investigación, muy interesante para mí puesto que mi objetivo es dedicarme a la oftalmología, siendo la retina mi subespecialidad favorita. También agradecer a la Dra. Pilar de Rivas, jefa del servicio de Oftalmología del Hospital de Sant Pau i Santa Tecla, por proporcionarme material muy útil de varios congresos relacionado con el tema de este trabajo, y a los adjuntos Mireia Garriga y Jordi Martín, por aclararme y explicarme varios conceptos durante mi rotación con ellos.

REFERENCIAS BIBLIOGRÁFICAS

1. Almuiña P, Ascaso Puyuelo J, Bermúdez Pérez C, Bernal-Morales C, Donate López J, González Zamora J, Ispa Callén C, de Moura J, Novo J, Ortega M, Penedo M, Rodrigo Bello J y Rodríguez Martín J. Inteligencia Artificial en Retina. Monografía [Internet]. Sociedad Española de Retina y Vítreo; 2020 [consultado 1 nov 2020]. Disponible en: https://serv.es/wp-content/pdf/guias/Monografia_Inteligencia_Artificial_en_Retina.pdf
2. Ernst & Young. Informe sobre la ceguera en España [Internet]. Fundación Retina Plus [consultado 2 nov 2020]. Disponible en: https://www.seeof.es/archivos/articulos/adjunto_20_1.pdf
3. Arias Barquet L, Cabrera López F, García Arumí J, García Layana A, Ruiz Moreno J. Protocolo de diagnóstico, seguimiento y recomendaciones generales en la degeneración macular asociada a la edad (DMAE) precoz e intermedia: consenso de un panel de expertos [Internet]. Sociedad Española de Retina y Vítreo; 2016 [consultado 2 nov 2020]. Disponible en: https://serv.es/wp-content/descargasWP/documentacionMedica/consenso_DMAE.pdf
4. Ferris FL 3rd, Wilkinson CP, Bird A, Chakravarthy U, Chew E, Csaky K, et al. Clinical classification of age-related macular degeneration. *Ophthalmology*. 2013;120:844-51.
5. Almiñana A, Fernández Martínez C, Hernández Artola F, Martínez Toldos JJ. Actualización en autofluorescencia retiniana. Revista de información e investigación oftalmológica de Laboratorios Thea [Internet]. 2013 [consultado 5 nov 2020];(067). Disponible en: https://www.laboratoriosthea.com/medias/thea_informacion_67.pdf
6. Burlina P, Pacheco KD, Joshi N, Freund DE, Bressler NM. Comparing humans and deep learning performance for grading AMD: A study in using universal deep features and transfer learning for automated AMD analysis. *Comput Biol Med* [Internet]. 2017 Mar [consultado 22 may 2021]; 82:80-86. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/28167406/>
7. Kunumpol P, Umpaipant W, Kanchanaranya N, Charoenpong T, Vongkittirux S, Kupakanjana T, Tantibundhit C. Automated Age-related Macular Degeneration screening system using fundus images. *Annu Int Conf IEEE Eng Med Biol Soc* [Internet]. 2017 Jul [consultado 22 may 2021]; 2017:1469-1472. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/29060156/>
8. Burlina PM, Joshi N, Pekala M, Pacheco KD, Freund DE, Bressler NM. Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks. *JAMA Ophthalmol* [Internet]. 2017 Nov [consultado 22 may 2021]; 135(11):1170-1176. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/28973096/>
9. Ting DSW, Cheung CY, Lim G, Tan GSW, Quang ND, Gan A, Hamzah H, Garcia-Franco R, San Yeo IY, Lee SY, Wong EYM, Sabanayagam C, Baskaran M, Ibrahim F, Tan NC, Finkelstein EA, Lamoureux EL, Wong IY, Bressler NM, Sivaprasad S, Varma R, Jonas JB, He MG, Cheng CY, Cheung GCM, Aung T, Hsu W, Lee ML, Wong TY. Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. *JAMA* [Internet]. 2017 Dec [consultado 22 may 2021]; 318(22):2211-2223. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/29234807/>
10. Govindaiah A, Smith RT, Bhuiyan A. A New and Improved Method for Automated Screening of Age-Related Macular Degeneration Using Ensemble Deep Neural Networks. *Annu Int Conf IEEE Eng Med Biol Soc* [Internet]. 2018 Jul [consultado 22 may 2021]; 2018:702-705. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30440493/>
11. Grassmann F, Mengelkamp J, Brandl C, Harsch S, Zimmermann ME, Linkohr B, Peters A, Heid IM, Palm C, Weber BHF. A Deep Learning Algorithm for Prediction of Age-Related Eye Disease Study Severity Scale for Age-Related Macular

- Degeneration from Color Fundus Photography. *Ophthalmology* [Internet]. 2018 Sep [consultado 22 may 2021]; 125(9):1410-1420. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/29653860/>
12. Peng Y, Dharssi S, Chen Q, Keenan TD, Agrón E, Wong WT, Chew EY, Lu Z. DeepSeeNet: A Deep Learning Model for Automated Classification of Patient-based Age-related Macular Degeneration Severity from Color Fundus Photographs. *Ophthalmology* [Internet]. 2019 Apr [consultado 22 may 2021]; 126(4):565-575. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30471319/>
 13. Keenan TD, Dharssi S, Peng Y, Chen Q, Agrón E, Wong WT, Lu Z, Chew EY. A Deep Learning Approach for Automated Detection of Geographic Atrophy from Color Fundus Photographs. *Ophthalmology* [Internet]. 2019 Nov [consultado 22 may 2021]; 126(11):1533-1540. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31358385/>
 14. Zapata MA, Royo-Fibla D, Font O, Vela JI, Marcantonio I, Moya-Sánchez EU, Sánchez-Pérez A, Garcia-Gasulla D, Cortés U, Ayguadé E, Labarta J. Artificial Intelligence to Identify Retinal Fundus Images, Quality Validation, Laterality Evaluation, Macular Degeneration, and Suspected Glaucoma. *Clin Ophthalmol* [Internet]. 2020 Feb [consultado 22 may 2021]; 14:419-429. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32103888/>
 15. Bhuiyan A, Wong TY, Ting DSW, Govindaiah A, Souied EH, Smith RT. Artificial Intelligence to Stratify Severity of Age-Related Macular Degeneration (AMD) and Predict Risk of Progression to Late AMD. *Transl Vis Sci Technol* [Internet]. 2020 Apr [consultado 22 may 2021]; 9(2):25. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32818086/>
 16. González-Gonzalo C, Sánchez-Gutiérrez V, Hernández-Martínez P, Contreras I, Lechanteur YT, Domanian A, van Ginneken B, Sánchez CI. Evaluation of a deep learning system for the joint automated detection of diabetic retinopathy and age-related macular degeneration. *Acta Ophthalmol* [Internet]. 2020 Jun [consultado 22 may 2021]; 98(4):368-377. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31773912/>
 17. Dong L, Yang Q, Zhang RH, Wei WB. Artificial intelligence for the detection of age-related macular degeneration in color fundus photographs: A systematic review and meta-analysis. *EClinicalMedicine* [Internet]. 2021 May [consultado 22 may 2021]; 35:100875. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/34027334/>
 18. Lee CS, Baughman DM, Lee AY. Deep learning is effective for the classification of OCT images of normal versus Age-related Macular Degeneration. *Ophthalmol Retina* [Internet]. 2017 Jul-Aug [consultado 23 may 2021]; 1(4):322-327. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30693348/>
 19. Khalid S, Akram MU, Hassan T, Jameel A, Khalil T. Automated Segmentation and Quantification of Drusen in Fundus and Optical Coherence Tomography Images for Detection of ARMD. *J Digit Imaging* [Internet]. 2018 Aug [consultado 23 may 2021]; 31(4):464-476. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/29204763/>
 20. Hwang DK, Hsu CC, Chang KJ, Chao D, Sun CH, Jheng YC, Yarmishyn AA, Wu JC, Tsai CY, Wang ML, Peng CH, Chien KH, Kao CL, Lin TC, Woung LC, Chen SJ, Chiou SH. Artificial intelligence-based decision-making for age-related macular degeneration. *Theranostics* [Internet]. 2019 Jan [consultado 23 may 2021]; 9(1):232-245. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30662564/>
 21. Yoo TK, Choi JY, Seo JG, Ramasubramanian B, Selvaperumal S, Kim DW. The possibility of the combination of OCT and fundus images for improving the diagnostic accuracy of deep learning for age-related macular degeneration: a preliminary experiment. *Med Biol Eng Comput* [Internet]. 2019 Mar [consultado 23 may 2021]; 57(3):677-687. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30349958/>
 22. Saha S, Nassisi M, Wang M, Lindenberg S, Kanagasingham Y, Sadda S, Hu ZJ. Automated detection and classification of early AMD biomarkers using deep learning. *Sci Rep* [Internet]. 2019 Jul [consultado 23 may 2021]; 9(1):10990. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31358808/>

23. An G, Akiba M, Yokota H, Motozawa N, Takagi S, Mandai M, Kitahata S, Hiram Y, Takahashi M, Kurimoto Y. Deep Learning Classification Models Built with Two-step Transfer Learning for Age Related Macular Degeneration Diagnosis. *Annu Int Conf IEEE Eng Med Biol Soc* [Internet]. 2019 Jul [consultado 23 may 2021]; 2019:2049-2052. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31946304/>
24. Motozawa N, An G, Takagi S, Kitahata S, Mandai M, Hiram Y, Yokota H, Akiba M, Tsujikawa A, Takahashi M, Kurimoto Y. Optical Coherence Tomography-Based Deep-Learning Models for Classifying Normal and Age-Related Macular Degeneration and Exudative and Non-Exudative Age-Related Macular Degeneration Changes. *Ophthalmol Ther* [Internet]. 2019 Dec [consultado 23 may 2021]; 8(4):527-539. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31407214/>
25. Vaghefi E, Hill S, Kersten HM, Squirrel D. Multimodal Retinal Image Analysis via Deep Learning for the Diagnosis of Intermediate Dry Age-Related Macular Degeneration: A Feasibility Study. *J Ophthalmol* [Internet]. 2020 Jan [consultado 23 may 2021]; 2020:7493419. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32411434/>
26. Bindewald A, Jorzik JJ, Roth F, Holz FG. cSLO-Fundusautofluoreszenz-Imaging Methodische Weiterentwicklungen der konfokalen Scanning-Laser-Ophthalmoskopie [cSLO digital fundus autofluorescence imaging]. *Ophthalmologie* [Internet]. 2005 Mar; 102(3):259-64. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/15490188/>
27. Treder M, Lauer mann JL, Eter N. Deep learning-based detection and classification of geographic atrophy using a deep convolutional neural network classifier. *Graefes Arch Clin Exp Ophthalmol* [Internet]. 2018 Nov [consultado 23 may 2021]; 256(11):2053-2060. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30091055/>
28. Schmidt-Erfurth U, Waldstein SM, Klimscha S, Sadeghipour A, Hu X, Gerendas BS, Osborne A, Bogunovic H. Prediction of Individual Disease Conversion in Early AMD Using Artificial Intelligence. *Invest Ophthalmol Vis Sci* [Internet]. 2018 Jul [consultado 24 may 2021]; 59(8):3199-3208. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/29971444/>
29. Russakoff DB, Lamin A, Oakley JD, Dubis AM, Sivaprasad S. Deep Learning for Prediction of AMD Progression: A Pilot Study. *Invest Ophthalmol Vis Sci* [Internet]. 2019 Feb [consultado 24 may 2021]; 60(2):712-722. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30786275/>
30. Waldstein SM, Vogl WD, Bogunovic H, Sadeghipour A, Riedl S, Schmidt-Erfurth U. Characterization of Drusen and Hyperreflective Foci as Biomarkers for Disease Progression in Age-Related Macular Degeneration Using Artificial Intelligence in Optical Coherence Tomography. *JAMA Ophthalmol* [Internet]. 2020 Jul [consultado 23 may 2021]; 138(7):740-747. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32379287/>
31. Waldstein SM, Seeböck P, Donner R, Sadeghipour A, Bogunović H, Osborne A, Schmidt-Erfurth U. Unbiased identification of novel subclinical imaging biomarkers using unsupervised deep learning. *Sci Rep* [Internet]. 2020 Jul [consultado 23 may 2021]; 10(1):12954. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32737379/>
32. Schmidt-Erfurth U, Bogunovic H, Grechenig C, Bui P, Fabianska M, Waldstein S, Reiter GS. Role of Deep Learning-Quantified Hyperreflective Foci for the Prediction of Geographic Atrophy Progression. *Am J Ophthalmol* [Internet]. 2020 Aug [consultado 23 may 2021]; 216:257-270. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32277942/>
33. Banerjee I, de Sisternes L, Hallak JA, Leng T, Osborne A, Rosenfeld PJ, Gregori G, Durbin M, Rubin D. Prediction of age-related macular degeneration disease using a sequential deep learning approach on longitudinal SD-OCT imaging biomarkers. *Sci Rep* [Internet]. 2020 Sep [consultado 23 may 2021]; 10(1):15434. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32963300/>
34. Brady CJ, Garg S. Telemedicine for Age-Related Macular Degeneration. *Telemed J E Health* [Internet]. 2020 Apr [consultado 30 may 2021]; 26(4):565-568. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/32209019/>

35. Hwang DK, Hsu CC, Chang KJ, Chao D, Sun CH, Jheng YC, Yarmishyn AA, Wu JC, Tsai CY, Wang ML, Peng CH, Chien KH, Kao CL, Lin TC, Woung LC, Chen SJ, Chiou SH. Artificial intelligence-based decision-making for age-related macular degeneration. *Theranostics* [Internet]. 2019 Jan [consultado 30 may 2021]; 9(1):232-245. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/30662564/>
36. Nahen K, Benyamini G, Loewenstein A. Evaluation of a Self-Imaging SD-OCT System for Remote Monitoring of Patients with Neovascular Age Related Macular Degeneration. *Klin Monbl Augenheilkd* [Internet]. 2020 Dec [consultado 30 may 2021]; 237(12):1410-1418. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/33285588/>

Índice de figuras

Figura 1. Progresión de la visión en la DMAE húmeda. Fuente: Mácula-Retina, Asociación de Enfermos y Familiares.....	4
Figura 2. Prevalencia de DMAE en España. Fuente: elaboración propia.	4
Figura 3. Estadios de DMAE según Ferris et al. ⁴ (2013). Fuente: elaboración propia.	5
Figura 4. Neurona artificial. Fuente: Inteligencia Artificial en Retina. Monografía (SERV) ¹	7
Figura 5. Redes neurales. Fuente: Inteligencia Artificial en Retina. Monografía (SERV) ¹	7
Figura 6. Esquema general del proceso de reconocimiento de imágenes mediante IA. Fuente: elaboración propia.....	8
Figura 7. Revisión bibliográfica: selección de estudios. Fuente: elaboración propia.....	12
Figura 8. Precisión de los algoritmos de IA en la detección de DMAE mediante retinografías. Fuente: elaboración propia.	13
Figura 9. (a) Imagen de fondo de ojo de una retina normal [...]. Fuente: Khalid et al. ¹⁹ (2018).	14
Figura 10. (a) Imagen de fondo de ojo de una retina afectada por DMAE [...]. Fuente: Khalid et al. ¹⁹ (2018).	14
Figura 11. Precisión de los algoritmos de IA en la detección de DMAE mediante OCT. Fuente: elaboración propia.....	15
Figura 12. Esquema del interfaz y guía del software basado en IA-OCT en la nube. Fuente: Hwang et al. ³⁵ (2019).	20
Tabla 1. Retinografías de los estadios de DMAE según Ferris et al. ⁴ (2013). Fuente: elaboración propia.	5
Tabla 2. Utilidad de distintas pruebas de imagen en el diagnóstico de la DMAE seca y húmeda. Fuente: elaboración propia....	6
Tabla 3. Información de estudios sobre diagnóstico de DMAE por retinografías con IA. Fuente: elaboración propia.	13
Tabla 4. Información de estudios sobre diagnóstico de DMAE por OCT con IA. Fuente: elaboración propia.	15
Tabla 5. Información de estudios sobre diagnóstico de DMAE por autofluorescencia con IA. Fuente: elaboración propia.	16
Tabla 6. Información de estudios sobre pronóstico de DMAE con IA. Fuente: elaboración propia.	17
Tabla 7. Comparativa entre retinografías y OCT para su procesamiento mediante IA en el diagnóstico de DMAE. Fuente: elaboración propia.	19
Tabla 8. Utilidad de distintas pruebas de imagen para el diagnóstico, pronóstico y seguimiento de DMAE seca mediante IA. Fuente: elaboración propia.	21