



Universidad de Valladolid

PROGRAMA DE DOCTORADO EN CIENCIAS DE LA VISIÓN

TESIS DOCTORAL:

**DESARROLLO Y VALIDACIÓN DE UN ASISTENTE VIRTUAL
BASADO EN INTELIGENCIA ARTIFICIAL PARA APOYAR
LA TOMA DE DECISIÓN EN ATENCIÓN VISUAL PRIMARIA**

Presentada por Leandro Stuermer para optar
al grado de Doctor por la Universidad de Valladolid

Dirigida por:
Dr. Raúl Martín Herranz

Dedicación

A mi compañera de profesión, de investigación y de vida, *Sabrina Braga Vieira*, por haber recorrido conmigo este largo camino, enfrentando y superando los más diversos desafíos, y *Leonardo*, por hacer posible formar una familia que me fortalece a cada día.

A mis padres, *Lauro y Ana Maria*, por ser la razón que me impulsó a seguir esta profesión, por brindarme las mejores condiciones, y por inspirarme con su ejemplo de dedicación y ética.

A *Lili* (*in memoriam*), una persona especial que la vida me regaló, y cuya presencia marcó profundamente mi crecimiento.

“La mente es como un paracaídas: solo funciona si se abre”

Albert Einstein

“Lo que sabemos es una gota de agua; lo que ignoramos es el océano”

Isaac Newton

“No es la especie más fuerte la que sobrevive, ni la más inteligente, sino la que mejor se adapta al cambio”

Charles Darwin

“El genio es uno por ciento de inspiración y noventa y nueve por ciento de transpiración”

Thomas Edison

“Si he visto más lejos, es porque estoy sentado sobre los hombros de gigantes”

Isaac Newton

Agradecimientos

En primer lugar, a mi núcleo familiar: mi esposa **Sabrina** por ser mi fortaleza en la vida, en la profesión y ahora también en la investigación, y que, junto a mi ‘hijo’ **Leo**, constituyen los pilares de amor y equilibrio en los momentos más desafiantes; a mis padres, **Lauro y Ana Maria**, por su apoyo incondicional y por ser un ejemplo constante de vida, tanto en lo familiar como en lo profesional; a mi hermana, cuñado y ahijado (**Elida, Eduardo y ‘Rei’**) por su cercanía y cariño; y a todos los demás familiares que, de alguna manera, incentivaron en esta etapa.

También, a la memoria de quienes partieron durante este recorrido, cuya presencia permanece viva: mis suegros (**Riva y Marilene**), y **Lili**, una figura entrañable que me brindó afecto a lo largo de la vida.

A mi tutor y director de tesis, **Raúl Martín**, quien me ha guiado desde el máster y que, a lo largo de este doctorado, ha demostrado una paciencia incansable, sabiendo comprender y adaptar nuestras limitaciones, en especial de distancia e idioma. Más que un director, ha sido un maestro, un ejemplo y una fuente constante de inspiración. Sin duda alguna, este camino habría sido absolutamente inviable sin su apoyo permanente.

A la **IOBA y a la Universidad de Valladolid**, mi profundo agradecimiento por haberme acogido en esta trayectoria doctoral. Gracias por el respaldo institucional y por permitirme acercarme a profesionales de excelencia y al mundo de la investigación, algo que en mi contexto habitual habría sido inaccesible. Esta experiencia transformó mi percepción profesional y fortaleció mi desarrollo personal. Agradezco en especial a la **Dra. Yolanda Diebold** cuyas orientaciones

e incentivos oportunos guiaron este proceso, haciéndonos creer en nuestras metas; a la **Dra. Margarita Calonge**, quien, sin saberlo, fue la primera persona en sugerirme la posibilidad de realizar un doctorado, en la defensa del máster (algo impensable hasta aquel momento); y al **Prof. José Carlos Pastor** (*in memoriam*), quien también, sin saberlo, se convirtió en un puente constante con las instituciones y nos hizo sentir cerca incluso en la distancia, con su papel inspirador, su capacidad única de comunicarse y su alegría a través de las redes sociales. En la figura de estas personas, extendiendo mi gratitud a las instituciones.

Agradezco a la **Universidad del Contestado**, así como a todo su **cuerpo docente y estudiantil**, por el apoyo y acompañamiento que fueron fundamentales para el desarrollo de todas las etapas de esta tesis, constituyendo una base importante en esta trayectoria.

Agradezco a **Aston University**, representada en la persona del profesor **Dr. James Wolffsohn** y extensible a **todo el equipo**, por haberme recibido tan bien y por hacer posible la estancia internacional en el Reino Unido, que amplió no solo mis fronteras del conocimiento, sino también mis habilidades personales y profesionales.

Asimismo, a todas las personas que, de una u otra forma, apoyaron y acompañaron este camino, en especial a mis **alumnos, pacientes, colegas de trabajo, amigos y compañeros de la optometría brasileña**, cuyo entusiasmo y apoyo fueron una fuente de motivación.

Y, por qué no, a '**Pitoco**', quien, sin decir una palabra, me acompañó constantemente, regalándome paz y consuelo en los momentos más exigentes, y también mucha alegría a lo largo de este período.

A todos ustedes, mi agradecimiento por ser parte de esta etapa

Biografía breve

Formación académica: Graduado en Optometría por la Universidade Luterana do Brasil (ULBRA, 2003), primera promoción del país. Como complemento a su formación principal, además de Técnico en óptica, posee dos posgrados (*lato sensu*) en docencia y educación a distancia, así como estudios incompletos en Ciencias de la Computación (4 de 5 años). En 2016 obtuvo el Máster en Investigación en Ciencias de la Visión (UVa/IOBA), con doble especialización (óptica visual y fisiología/neurofisiología de la visión), con mención de honor; y desde 2017 es doctorando en Ciencias de la Visión en la misma institución.

Experiencia profesional: Con familia vinculada al sector de la óptica, está relacionado profesionalmente con este sector desde 1995, en áreas de laboratorio, gestión y marketing. Ejerce como optometrista desde 2003 en clínica privada. Desde 2009, también se ha dedicado a la docencia, fundando Estude Visão, impartiendo clases en cursos técnicos y, desde 2019, como profesor universitario en el grado de Optometría de la Universidad del Contestado (UnC), con el cargo de coordinador del grado y ha dirigido nueve trabajos finales.

Experiencia científica: Investigador predoctoral del Grupo de Investigación en Optometría del IOBA desde 2017, con tres publicaciones indexadas (dos como autor principal). Ha participado en diferentes eventos científicos en Brasil y presentado siete comunicaciones científicas internacionales. Realizó una estancia de investigación en la Aston University, en Birmingham, Reino Unido (sep–dic/2023).

Brief Biography

Academic Background: Graduated in Optometry from Universidade Luterana do Brasil (ULBRA, 2003), first cohort in the country. In addition to his main training, he holds a technical qualification in Optics and two postgraduate (*lato sensu*) qualifications in teaching and distance education, as well as incomplete studies in Computer Science (4 of 5 years). In 2016, he was awarded a Master's degree in Vision Science Research (UVa/IOBA), with double specialisation in visual optics and physiology/neurophysiology of vision, with honours. Since 2017 he has been a doctoral student in Vision Sciences at the same institution.

Professional Experience: With a family background in the optical sector, he has been professionally involved in this sector since 1995, working in areas such as laboratory operations, management, and marketing. He has been practicing as an optometrist in private clinics since 2003. Since 2009, he has also been engaged in teaching, founding Estude Visão, teaching in technical courses, and, since 2019, serving as a university lecturer in the Optometry program at Universidade do Contestado (UnC), with the role of Programme Lead and has supervised nine undergraduate projects.

Scientific Experience: Predoctoral researcher in the Optometry Research Group at IOBA since 2017, with three indexed publications (two as first author). He has participated in several scientific events in Brazil and presented seven scientific communications at international conferences. He undertook a research stay at Aston University in Birmingham, United Kingdom (Sep–Dec 2023).

Difusión de los Resultados

Esta tesis ha dado lugar a los siguientes resultados que se presentan, agrupados en diferentes categorías, por orden cronológico:

Publicaciones

Stuermer L, Martin R. **Characterization of technologies in digital health applied in vision care.** J. Optom. 2022;15; S70-81. doi: 10.1016/j.optom.2022.09.005
(*Fator de impacto: 2,3 – Q2 SCIE*).

Stuermer L, Braga S, Martin R, Wolffsohn JS. **Artificial intelligence virtual assistants in primary eye care practice.** Ophthalmic Physiol Opt. 2025;45:437–449. doi:10.1111/opo.13435.
(*Fator de impacto: 2,8 – Q1 SCIE*)

Comunicaciones en congresos

Poster

25º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica -OPTOM2018. Comunicación Póster: **Monitor vision: desarrollo de una app para el seguimiento y monitorización de los usuarios de lentes de contacto.** Stuermer L, Braga S, Ortiz S, Rodríguez G, Martín R. - al 28 de mayo de 2021. (España).

26º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica -OPTOM2021 (Online). Comunicación Póster: **Investigación sobre salud visual empleando e-health, big data e inteligencia artificial aplicada.** Stuermer L, Braga S, Martín R. - al 14 de abril de 2018. (España).

27º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica – OPTOM 2022. Comunicación Póster: **Disponibilidad y características de conjuntos de datos clínicos para uso en las ciencias de la visión.** Stuermer L, Braga S, Martín R. - al 03 de abril de 2022. (España).

28º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica – OPTOM 2024. Comunicación Póster: **Propuesta de plataforma big data para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular.** Stuermer L, Braga S, Martín R. - al 14 de abril de 2022. (España).

Comunicación oral / presentación

1º Congresso Interamericano de Optometria y Ciências de la Visión / 17º Congresso Internacional de Optometria. CIO2018 Ponencia: **Nueva APP para el seguimiento y monitorización de los usuarios de lentes de contacto: Monitor Vision.** Stuermer L. - al 30 de mayo de 2018. (Orlando, Estados Unidos).

28º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica - OPTOM2024. Comunicación Oral: **Asistente virtual basado en modelos de inteligencia artificial para apoyar la toma de decisión en atención visual primaria.** Stuermer L, Braga S, Martín R. al 14 de abril de 2024. (España).

1er Seminario Nacional de Optometría de la Universidad del Contestado. Ponencia: **Apoyo a la toma de decisiones en atención visual primaria: asistente virtual basado en inteligencia artificial.** Stuermer L. al 30 de mayo de 2025. (Brasil)

Premios

VI Jornada de Investigadores Predoctorales de la UVa em Ciencias de la Visión. Premio a la mejor comunicación. **Desarrollo y validación de un servicio de asistente virtual inteligente para apoyar la decisión clínica en atención visual primaria.** Stuermer L. al 30 de junio de 2022.

Página Web

Sitio web de acceso libre para divulgar los procesos de desarrollo relacionados con la salud visual digital. Stuermer L, Braga S. ***<https://www.visioncare.digital/>***

Financiación

Esta tesis no ha contado con financiación externa para su realización.

Sin embargo, la estancia internacional fue parcialmente financiada a través de las *Ayudas para estancias breves en el desarrollo de tesis doctorales* de la Universidad de Valladolid en la convocatoria de 2023.

Sesión
Session



PRESENTACIÓN

PRESENTATION



ÍNDICE / TABLE OF CONTENTS

PREFACIO _____ **I**

Preface

Dedicación	III
Frases	V
Agradecimientos	VII
Biografía breve	IX
<i>Brief Biography</i>	X
Difusión de los Resultados	XI
Financiación	XV

I - PRESENTACIÓN _____ **1**

Presentation

Índice / <i>Table of contents</i>	3
Abreviaturas / <i>Abbreviations</i>	9
Organización de la Tesis Doctoral	13
<i>Organization of the Doctoral Thesis (English)</i>	17

II - SUMMARY **21**

Summary in English

1. Introduction	23
2. Foundation and general design	27
3. Characterization of digital health technologies applied to vision care	29

4. Availability and characteristics of clinical datasets for use in vision sciences	31
5. Big data platform proposal for optometry based on a review of protocols and clinical data repository models in eye health	33
6. Development of artificial intelligence models in primary visual care	35
7. Development of the virtual assistant prototype in primary visual care	37
8. Validation of artificial intelligence models to support decision-making in visual and ocular health	39
9. Challenges and future lines	41
10. Conclusions.....	43

III - RESUMEN **45**

Summary in Spanish

1. Introducción.....	47
2. Fundamentación y planteamiento general.....	51
3. Caracterización de tecnologías en salud digital aplicadas en el cuidado de la visión	53
4. Disponibilidad y características de conjuntos de datos clínicos para su uso en ciencias de la visión	55
5. Propuesta de plataforma <i>big data</i> para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular	57
6. Desarrollo de modelos de inteligencia artificial en atención visual primaria.....	59
7. Desarrollo del prototipo del asistente virtual en atención visual primaria.....	61
8. Validación de modelos de inteligencia artificial para apoyar la toma de decisiones en salud visual y ocular	63

9. Desafíos y líneas futuras	65
10. Conclusiones.....	67

Capítulo 1: Introducción _____ 69

Introduction

1.1. Atención primaria en salud visual	73
1.1.1. Transformación digital en apoyo a AVP	76
1.2. Transformaciones digitales en salud	77
1.2.1. Tecnologías digitales aplicadas a la salud	77
1.2.2. Sistemas de apoyo en la práctica clínica	81
1.3. Datos clínicos como base para la innovación	83
1.3.1. Potencial, limitaciones y desafíos actuales	85
1.4. Asistentes virtuales en el ámbito de la salud	89
1.5. IA y sus aplicaciones en salud	93
1.5.1. Principios básicos y fundamentos de la IA	93
1.5.2. Aplicaciones de la IA en salud	110
1.6. IA en salud visual (estado del arte)	115
1.6.1. Aplicaciones por área en salud de la visión	116
1.6.2. Aplicaciones futuras	128

Capítulo 2: Fundamentación y planteamiento general _____ 133

Rationale and general design

2.1. Justificación.....	135
2.2. Hipótesis	137
2.3. Objetivos (general y específicos).....	139
2.4. Metodología general.....	141

Capítulo 3: Caracterización de tecnologías en salud digital aplicadas en el cuidado de la visión _____ 145

Characterization of digital health technologies applied to vision care

3.1. Introducción.....	147
3.2. Material y Método.....	151
3.3. Resultados y discusión.....	159
3.4. Difusión	177

Capítulo 4: Disponibilidad y características de conjuntos de datos clínicos para uso las ciencias de la visión _____ 181

Availability and characteristics of clinical datasets for use in vision sciences

4.1. Introducción.....	183
4.2. Material y Método.....	185
4.3. Resultados y discusión.....	189
4.4. Difusión	197

Capítulo 5: Propuesta de plataforma big data para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular ____ 199

Big data platform proposal for optometry based on a review of protocols and clinical data repository models in eye health

5.1. Introducción.....	201
5.2. Material y Método.....	203
5.3. Resultados y discusión.....	207
5.4. Difusión	223

Capítulo 6: Desarrollo de modelos de inteligencia artificial en atención visual primaria _____ **225**

Development of artificial intelligence models in primary visual care

6.1. Introducción.....	227
6.2. Material y Método.....	229
6.3. Resultados	237
6.4. Discusión	255
6.5. Difusión	263

Capítulo 7: Desarrollo del prototipo del asistente virtual en atención visual primaria _____ **265**

Development of the virtual assistant prototype in primary visual care

7.1. Introducción.....	267
7.2. Material y Método.....	269
7.3. Resultados y discusión.....	271
7.4. Difusión	289

Capítulo 8: Validación de un asistente de inteligencia artificial para apoyar la toma de decisiones en salud visual y ocular _____ **291**

Validation of an artificial intelligence assistant to support decision-making in visual and ocular health

8.1. Introducción.....	293
8.2. Material y Método.....	295
8.3. Resultados	301
8.4. Discusión	317
8.5. Difusión	325

Capítulo 9: Desafíos y líneas futuras	327
<i>Challenges and future lines</i>	

Capítulo 10: Conclusiones	333
<i>Conclusions</i>	

REFERENCIAS	337
<i>References</i>	

ANEXOS	365
<i>Annexes</i>	

A. Aprobación del Comité de Ética para la recopilación de datos	367
B. Aprobación del Comité de Ética para la encuesta de evaluación	369
C. Encuesta de evaluación en español.....	371

ABREVIATURAS / ABBREVIATIONS

Las abreviaturas utilizadas en la Tesis Doctoral se presentan a continuación, habiendo sido definidas en su primera mención y reiteradas al inicio de cada capítulo para facilitar la lectura de la Tesis Doctoral.

Ac	Exactitud	<i>Accuracy</i>	
ANN	Redes neuronales artificiales	<i>Artificial neural networks</i>	
APP	Aplicación	<i>Application</i>	
AsV	Asistente virtual	<i>Virtual assistant</i>	VA
AV	Agudeza visual	<i>Visual acuity</i>	
AVP	Atención visual primaria	<i>Primary Visual Care</i>	PVC
BDi	Base de datos inicial	<i>Initial database</i>	
BDm	Base de datos modelada	<i>Modeled database</i>	
CDSS	Sistemas de apoyo a la toma de decisiones clínicas	<i>Clinical decision support systems</i>	
CDW	Clinical data warehouses	<i>Clinical data warehouses</i>	
CNN	Redes neuronales convolucionales	<i>Convolutional neural networks</i>	
CV	Cover test	<i>Cover test</i>	
DAVIH	Datos en Salud de la Visión	<i>Data Vision Health</i>	

DL	Aprendizaje profundo	<i>Deep learning</i>	
DMAE	Degeneración macular asociada a la edad	<i>Age-related Macular Degeneration</i>	
DT	Árbol de Decisión	<i>Decision tree</i>	
FDA	Administración de alimentos y medicamentos de los estados unidos	<i>Food and Drug Administration</i>	
Fs	Índice f1	<i>F1 score</i>	
GAO	Government accountability office	<i>Government accountability office</i>	
GC	Grupo control	<i>Control group</i>	<i>CG</i>
GI	Grupo intervención	<i>Intervention group</i>	<i>IG</i>
IA	Inteligencia artificial	<i>Artificial intelligence</i>	<i>AI</i>
IDR	Integrated data repositories	<i>Integrated data repositories</i>	
IoT	Internet de las cosas	<i>Internet of things</i>	
ISNT	Inferior, superior, nasal, temporal	<i>Inferior, superior, nasal, temporal</i>	
LLM	Modelo de lenguaje de gran escala	<i>Large-scale language model</i>	
LR	Regresión Logística	<i>Logistic regression</i>	
M1	Modelo 1	<i>Model 1</i>	
M2	Modelo 2	<i>Model 2</i>	
M3	Modelo 3	<i>Model 3</i>	
MAE	Error absoluto medio	<i>Mean absolute error</i>	
ML	Aprendizaje automático	<i>Machine learning</i>	
Nb	Normalizados balanceados	<i>Normalized balanced</i>	
Nd	Normalizados desbalanceados	<i>Normalized unbalanced</i>	

NN	Redes neuronales	<i>Neural networks</i>	
Ob	Originales balanceados	<i>Original balanced</i>	
OCT	Tomografía de coherencia óptica	<i>Optical coherence tomography</i>	
Od	Originales desbalanceados	<i>Original unbalanced</i>	
PLN	Procesamiento de lenguaje natural	<i>Natural language processing</i>	
PPC	Punto próximo de convergencia	<i>Near point of convergence</i>	
Pr	Precisión	<i>Precision</i>	
R²	Coeficiente de determinación	<i>Coefficient of Determination</i>	
RDW	Research data warehouses	<i>Research data warehouses</i>	
RES	Registros electrónicos de salud	<i>Electronic health records</i>	<i>EHR</i>
RF	Bosque Aleatorio	<i>Random forest</i>	
RMSE	Error cuadrático medio	<i>Mean square error</i>	
RNN	Redes neuronales recurrentes	<i>Recurrent neural networks</i>	
Se	Sensibilidad	<i>Sensitivity</i>	
SMOTE	Técnica de sobremuestreo de minorías sintéticas	<i>Synthetic minority oversampling technique</i>	
Sp	Especificidad	<i>Specificity</i>	
SVM	Máquina de Soporte Vectorial	<i>Support vector machine</i>	
TICs	Tecnologías de información y comunicación	<i>Information and communication technologies.</i>	
VICHI	Asistente Inteligente para el Cuidado Visual	<i>Vision Care Helper Intelligence</i>	
VB	Visión binocular	<i>Binocular vision</i>	



ORGANIZACIÓN DE LA TESIS DOCTORAL

La presente Tesis Doctoral opta al grado de Doctor con mención internacional. Ha sido dirigida por el Dr. Raul Martin Herranz y ha contado con una estancia de investigación en la Aston University (Reino Unido), bajo la supervisión del Dr. James S. Wolffsohn.

La memoria ha sido redactada en español, con un apartado de resumen presentado en idioma inglés (Sección II), que incluye las subsecciones de hipótesis, objetivos y conclusiones, así como el bloque de “Organización de la tesis”, presentado de forma íntegra en dicho idioma.

La tesis se presenta en la modalidad ordinaria y se estructura en nueve capítulos, integrados como parte de una narrativa de investigación común, cuya forma de presentación ha sido definida con el fin de garantizar la claridad expositiva y preservar la coherencia metodológica y conceptual de su conjunto, distribuyéndose y describiéndose de la siguiente manera:

- **Capítulo 1:** *Introducción*, en el que se abordan de forma articulada los principales ejes temáticos que sustentan el desarrollo de la investigación realizada, incluyendo la atención visual primaria en salud visual, la salud digital, los datos clínicos electrónicos, los asistentes virtuales, la inteligencia artificial en el ámbito sanitario y el estado del arte de su aplicación en la salud visual.

- **Capítulo 2:** Fundamentación y planteamiento general, en el que se desarrollan la justificación, la hipótesis, los objetivos generales y específicos, así como la descripción de la metodología general que expone el concepto progresivo adoptado para la presentación integral de la tesis.
- **Capítulos 3 a 8:** Se estructuran como capítulos diferenciados, cada uno correspondiente a una fase específica del proceso global de la investigación realizada y vinculada directamente con uno de los objetivos planteados. Dada la característica multidisciplinar de la tesis, se ha optado por una organización interna que presenta apartados orientados a la contextualización, método aplicado, resultados y discusión, con las limitaciones y perspectivas integradas, así como la diseminación de los resultados, en cada capítulo:
 - **Capítulos 3, 4 y 5:** Conforman el primer bloque de carácter exploratorio. El Capítulo 3 se centra en la caracterización de las tecnologías digitales aplicadas al cuidado visual. El Capítulo 4 examina la disponibilidad, el perfil y las limitaciones de los conjuntos de datos clínicos públicos utilizados en ciencias de la visión. Por último, el Capítulo 5 propone un modelo de plataforma global para el almacenamiento estructurado de datos clínicos optométricos.
 - **Capítulos 6, 7 y 8:** Este segundo bloque está enfocado en el desarrollo tecnológico y en la validación. El Capítulo 6 describe la generación de modelos predictivos

entrenados con datos clínicos reales. El Capítulo 7 aborda la construcción técnica del prototipo del asistente virtual, incluyendo su arquitectura, funcionalidades e interfaz. Finalmente, el Capítulo 8 verifica, con profesionales de la salud visual, el impacto y la influencia de la recomendación basada en IA como herramienta de apoyo en la toma de decisiones.

Respecto a la presentación de los resultados y la discusión, en los Capítulos 3, 4, 5 y 7, se presentan de forma conjunta en una sola sección ya que facilita la interpretación de los resultados, mientras que en los Capítulos 6 y 8, al abordar actividades centrales de la Tesis, se ha optado por presentarlo por separado lo que facilita un mayor nivel de profundización especialmente en la discusión y aplicabilidad de los resultados.

- **Capítulo 9:** Desafíos y líneas futuras, en la que se destacan aspectos que no están vinculados directamente a cuestiones científicas abordadas en los capítulos anteriores, sino que responden a aspectos de orden general relevantes a lo largo del desarrollo de la tesis.
- **Capítulo 10:** Conclusiones, que presenta las conclusiones, en inglés, obtenidas en esta Tesis Doctoral.

La representación esquemática general de la organización de la tesis se presenta en la Figura 0.1.




Figura 0.1. Representación esquemática de la organización de la tesis. Los círculos numerados representan los capítulos. El fondo azul indica las acciones con enfoque exploratorio, y el fondo amarillo, las actividades orientadas al enfoque principal de la Tesis Doctoral que suponen su novedad.



ORGANIZATION OF THE DOCTORAL THESIS

This Doctoral Thesis applies to the degree of Doctor with international mention. It has been supervised by Dr. Raúl Martín Herranz and includes a research stay at Aston University (United Kingdom), supervised by Dr. James S. Wolffsohn.

The manuscript has been written in Spanish, with a summary section presented in English (Section II), which includes the subsections of hypothesis, objectives, conclusions, and the “Organization of the Thesis”.

The thesis is presented in the ordinary modality and it is structured into nine chapters, integrated as part of a common research narrative. This format has been defined to ensure expository clarity and preserve the methodological and conceptual coherence of the whole, and it is organized and described as follows:

- **Chapter 1:** *Introduction*, which presents the main thematic axes supporting the development of the research, including primary visual care, digital health, electronic clinical data, virtual assistants, artificial intelligence in healthcare, and the state of the art of its application in visual health.

- **Chapter 2:** Rationale and general design, which develops the justification, the hypothesis, the general and specific objectives, and the description of the general methodology, as well as. The progressive concept adopted for the comprehensive presentation of the thesis is also presented.
- **Chapters 3 to 8:** These are structured as different chapters, each one corresponding to a specific phase of the overall research process and directly linked to one of the proposed objectives. Given the multidisciplinary nature of the thesis, an internal organization has been adopted in each chapter, with sections focused on contextualization, applied methodology, results and discussion, integrated limitations, perspectives, and dissemination of results:
 - **Chapters 3, 4, and 5:** Form the first block with an exploratory character. Chapter 3 focuses on the characterization of digital technologies applied to visual care. Chapter 4 examines the availability, profile, and limitations of public clinical data sets used in vision sciences. Finally, Chapter 5 proposes a global platform model for the structured storage of optometric clinical data.
 - **Chapters 6, 7, and 8:** This second block focuses on technological development and validation. Chapter 6 describes the generation of predictive models trained with real clinical data. Chapter 7 addresses the technical construction of the virtual assistant prototype, including its architecture, functionalities, and interface. Finally, Chapter

8 examines, with visual health professionals, the impact and influence of AI-based recommendations as a decision-support tool.

Regarding the presentation of results and discussion, in Chapters 3, 4, 5, and 7, these sections are presented jointly to facilitate the interpretation of findings. In contrast, in Chapters 6 and 8, which address core activities of the thesis, results and discussion are presented separately to allow a greater level of depth, especially in discussing the applicability of findings.

- **Chapter 9:** *Challenges and future directions*, which highlights aspects not directly linked to the scientific questions addressed in previous chapters but related to general issues relevant throughout the thesis development.
- **Chapter 10:** *Conclusions*, which presents the conclusions, written in English, obtained in this Doctoral Thesis.

The general schematic representation of the thesis organization is presented in Figure 0.2.




Figure 0.2. Schematic representation of the thesis organization. The numbered circles represent the chapters. The blue background indicates exploratory-focused actions, while the yellow background highlights the activities oriented towards the main focus of the Doctoral Thesis, which constitute its novelty.

Sesión
Session



SUMMARY

Summary in English



Chapter 1. Introduction

This Doctoral Thesis is situated at the intersection of multiple fields of knowledge, integrating visual health, digital health, and artificial intelligence (AI) within a coherent and interdisciplinary conceptual framework.

Primary visual care: Primary visual care (PVC) represents a strategic pillar for the early detection and timely management of ocular conditions, most of which are preventable or treatable if addressed in time. However, in many contexts, its effectiveness is compromised by the lack of human and technological resources, as well as the absence of standardized protocols and insufficient staff training. In response to these challenges, the integration of digital technologies and AI-based solutions, alongside collaborative models and telehealth, has proven to be a promising pathway for improving access, diagnostic accuracy, and care efficiency, thereby strengthening the problem-solving capacity of eye care at the community level.

Digital transformations in health: Digital transformation in health has evolved beyond the mere incorporation of isolated technologies into a structural reconfiguration of care models, integrating digital tools across all stages of care, from prevention to follow-up. This process has accelerated in the wake of the COVID-19 pandemic, which spurred the massive use of solutions such as eHealth, mHealth, telemedicine, the

Internet of Things, and wearable devices, each with specific applications to enhance accessibility, streamline processes, and strengthen continuity of care. In the field of visual health, these technologies have enabled the development of self-assessment tools, remote monitoring, screening systems, and image analysis platforms, among others. However, their adoption still faces barriers related to variability in tool quality and ethical challenges posed by automation. In this context, clinical decision support systems stand out as valuable resources for strengthening professional practice and improving diagnostic precision.

Clinical data as a foundation for innovation: Within the framework of Big Data, the growth of electronic clinical data has transformed these records into a strategic resource for innovation in health, enabling the development of AI-based solutions and improving service management. This expansion, driven by digital technologies, relies on infrastructures such as Electronic Health Records (EHRs) and integrated repositories, which consolidate information from multiple sources within secure and reusable environments. Nevertheless, significant challenges remain, including a lack of standardization, interoperability issues, and ethical barriers related to privacy, consent, and responsible data use. Despite these challenges, well-organized and accessible data under ethical frameworks can contribute to developing solutions ranging from population trend analysis to the design of personalized interventions, enabling more predictive, efficient, and patient-centred care.

Virtual assistants in health care: Virtual assistants (VAs), conceived as digital tools capable of interacting through natural language, have led to numerous applications in health care, thanks to advancements in AI and the expansion of accessible platforms. Thus, VAs have extended


their use from administrative functions to screening, chronic disease monitoring, and health education. Although their application in visual health is still emerging, there are promising initiatives in basic guidance and patient support, reinforcing their potential as a strategic resource to improve access, facilitate communication, and complement decision-making.

Artificial intelligence and its applications in health: AI refers to the development of systems capable of performing tasks that typically require human intelligence, such as pattern recognition, learning, or decision-making. Its operation is based on models trained through Machine Learning (ML) and Deep Learning (DL) algorithms that process data and generate outputs such as predictions or classifications. These models can be developed under different learning modalities and encompass tasks ranging from medical image classification to language generation. Understanding their principles allows for a clearer interpretation of their applications in diverse contexts.

In the healthcare field, AI has demonstrated enormous potential to transform care processes, thanks to its ability to analyse large volumes of clinical data, identify complex patterns, and generate useful recommendations for patient care. From automated screening tools and image analysis to predictive models of therapeutic response, its integration across health specialties has expanded diagnostic possibilities and improved operational efficiency. Rather than replacing professionals, AI acts as a complementary support that optimizes clinical decision-making processes, especially useful in high-demand or resource-limited settings. However, it also presents challenges such as bias risks, data privacy concerns, and the interpretation of results in

complex models. Thus, a critical understanding of its applications and limitations is essential to ensure safe, responsible, and effective implementation.

AI in visual health: This section presented a state of the art in these fields, highlighting that visual health has emerged as one of the most fertile environments for AI application, driven by the abundance of visual data, diagnostic standardization, and advancements in imaging technologies. DL-based models have been widely applied to the analysis of fundus photography, optical coherence tomography (OCT), and corneal topographies, achieving results that match or surpass the accuracy of conventional clinical examinations in conditions such as diabetic retinopathy, glaucoma, or keratoconus. These tools enable population-level screenings, support surgeries, and assist in refractive planning, thereby expanding access and improving clinical efficiency. Beyond diagnostic applications, uses in education, support for individuals with low vision, and automated recommendation generation are also being explored. As an emerging field, the concept of *oculomics* proposes using ocular analysis as a pathway for detecting systemic diseases, through algorithms that process retinal images to identify biomarkers of cardiovascular risk, biological aging, or cognitive decline.



Chapter 2. Rationale and general design

Justification: PVC plays a strategic role in preventing visual impairment and improving access to eye care. However, it faces limitations arising from a shortage of professionals, territorial inequalities, and a growing demand. In this context, the integration of digital technologies - particularly AI - emerges as a promising solution. AI has demonstrated great potential in clinical tasks such as image analysis and disease classification, although its application in accessible environments and within the field of optometry remains limited. This thesis proposes the development of an AI-based VA that integrates clinical data, technology, and visual health knowledge to support decision-making in PVC. This proposal is justified on three pillars: the relevance of the problem, the current technological opportunity, and the operational feasibility to generate a useful and scalable solution.

Hypothesis: The development of an AI-based VA, trained with specific clinical data, may constitute a relevant and feasible tool to support decision-making in PVC through the analysis of signs, symptoms, and clinical examination results.

General Objective: To develop and validate an AI-based VA to support decision-making in PVC.

Specific Objectives:

1. To analyse the development of research in digital health applied to vision sciences, characterizing its relationship with visual care and describing the technologies proposed in this field.
2. To analyse the availability and characteristics of public datasets related to vision sciences.
3. To propose a global platform model for clinical data storage, based on EHR standards and current repository models.
4. To generate AI models trained with optometric clinical data, aimed at supporting decision-making in PVC.
5. To develop an application in the form of a VA that integrates AI models, facilitating its use in clinical and educational contexts.
6. To evaluate the influence of the VA on clinical decision-making in visual health, as well as professionals' perceptions of its use.

General Methodology: The thesis is organized into two complementary blocks to achieve all objectives. The first, exploratory in nature, encompasses the review of digital technologies in visual health (1), data availability (2), and the proposal of a data storage platform (3). The second focuses on the development and validation of the VA (4, 5, and 6), including the generation of predictive models, creation of the application, and evaluation of its impact. Each chapter applies specific methodologies according to the needs of its corresponding objective, integrated within a progressive logic aimed at fulfilling the general objective.



Chapter 3. Characterization of digital health technologies applied to vision care

Digital health has transformed vision care by introducing technologies that optimize the diagnosis, management, and treatment of ocular diseases. This chapter aimed to analyse the scientific production on digital technologies applied to visual health between 2012 and 2021.

An exploratory review was conducted in SCOPUS, focusing on English-language articles published in health and computing journals. The search employed terms related to visual health and technologies such as AI, big data, virtual reality, and telehealth, considering publications from the past decade. After applying inclusion and exclusion criteria, 1,069 articles were identified for analysis. These were classified according to the technology used, the ocular structures or conditions addressed, and the type of application proposed.

The results showed sustained growth in publications, with 84.4% of studies published between 2017 and 2021. AI emerged as the most utilized technology (77.7%), particularly through DL for image analysis, followed by eHealth (68.6%) and mHealth (60.9%). Big data appeared in 13.7% of the works, while other technologies such as virtual and augmented reality had lower representation. Most studies originated from Asia and North America, led by the United States, China, and India, while Europe, Oceania, Africa, and Latin America made more limited contributions.

Regarding ocular health, the retina was the most analysed structure (93.3% of studies focused on the posterior pole), with particular emphasis on diseases such as diabetic retinopathy and glaucoma. The anterior segment received less attention (10.9%), as did the visual pathway (3.9%). Approximately one-quarter of articles did not clearly identify the ocular structure evaluated, and one-third did not specify the visual condition addressed. Clinical applications predominated (93.7%), mainly supporting diagnosis, analysis, and classification, while only 15.2% of studies included applications directed at PVC. In the non-clinical field, standardization, telemedicine, and data management stood out as emerging areas.

These findings highlight a concentration of advanced technologies oriented toward secondary and tertiary care, with a marked focus on the retina as the predominant structure of study, while tools aimed at strengthening PVC remain limited. This chapter was published in the special issue “*Artificial Intelligence, Data Science and E-health in Vision Research and Clinical Activity*” of the Journal of Optometry (2022), and its preliminary results were presented at the 26th International Congress of Optometry, Contactology, and Ophthalmic Optics (OPTOM, 2021 – online edition).



Chapter 4. Availability and characteristics of clinical datasets for use in vision sciences

Access to clinical datasets is essential to drive research and technological development in visual health, enabling the analysis of large volumes of information quickly and feasibly. In the field of vision sciences, these resources support epidemiological studies and the development of AI algorithms applied to the diagnosis and treatment of ocular diseases. This chapter aimed to explore the public availability of datasets related to visual health.

A systematic search was conducted in Google Data Set Search between January 2019 and September 2021, using the terms “optometry” “ophthalmology” and “eye care”. The selection included only publicly accessible data linked to ocular health. After excluding 28 duplicates and 42 irrelevant datasets, 362 datasets were analysed. These were classified by format, source, accessibility, thematic profile, level of care, and relation to ocular structures or pathologies. The analysis used a quantitative approach to describe trends and patterns.

The results showed that 44.2% of the datasets were retrieved with the term “ophthalmology”, 43.6% with “eye care” and only 12.2% with “optometry”. Most datasets offered free access (64.1%), and the most common formats were tables (52.2%), documents (24.6%), and images (12.4%), while 30.4% were classified as “others”, reflecting a diversity of structures that may hinder standardized use. The main sources

identified were [statista.com](https://www.statista.com), with 127 datasets, followed by data.mendeley.com and figshare.com, although the absence of specialized repositories in vision sciences stands out as a limitation.

Regarding thematic profile, 46.1% of the data related to health, and 26.2% had clinical content. Clinical data were concentrated mainly at the secondary (58%) and tertiary (27%) levels of care, while only 15% were linked to PVC. The most represented areas were retina (19.8%), general examinations (15.6%), anterior segment (13.5%), and surgery (11.5%). In contrast, topics such as refraction, low vision, ophthalmic lenses, and amblyopia each accounted for less than 1%. This distribution reveals a focus on specialized contexts, with significant gaps in resources applicable to PVC.

These findings underscore the need to develop specific platforms and standardization strategies to expand access and optimize the use of data in research and technological developments in vision sciences, particularly considering that most identified clinical datasets focus on the retina and posterior pole, leaving notable gaps in other areas. The results of this study were presented at the OPTOM 2022 Congress.



Chapter 5. Big data platform proposal for optometry based on a review of protocols and clinical data repository models in eye health

The storage and management of clinical data are strategic elements for driving research and technological innovation in health. This chapter proposes a global platform for optometry, developed from a review of standards in EHRs and current repository models in vision sciences. This proposal is justified as a response to the findings of the previous chapters, particularly the gaps identified in the availability of clinical data for ocular health in Chapter 4.


The study was conducted in three stages. First, standards and guidelines for EHRs were reviewed through a PubMed search, identifying seven relevant articles published between 2019 and 2023. A total of 24 elements were extracted and classified into four categories: interoperability (45.8%), accessibility (29.1%), security (54.1%), and privacy (12.5%). Key standards identified included HL7, FHIR, DICOM, PACS, and security protocols such as SSL/TLS, as well as anonymization policies and regulations like the GDPR.

In the second stage, 13 ocular health data repository platforms were identified, of which only five had associated scientific publications. The IRIS platform, managed by the *American Academy of Ophthalmology*, accounted for 43% of the publications (82 references), followed by FRB! (28.3%) and INSIGHT (20.9%). However, most of these systems are

specialized in posterior segment diseases, leaving key areas of optometry and PVC uncovered. Recent initiatives such as the *UK Eye Care Data Hub* and *Optometry 2040* indicate a trend toward broader and more accessible solutions oriented to this field.

The third stage integrated these findings into the conceptual design of DAVIH (*Data Vision Health*), a proposed platform for collecting, storing, and analysing data in visual health. It is structured into modules that include “inputs” from EHRs and clinical applications, secure cloud storage, and “outputs” for access by authorized researchers and professionals. The implemented protocols ensure interoperability, security, and privacy, while its governance model considers an international consortium to facilitate global development.

The proposal addresses the need to overcome data fragmentation, especially in optometry, and could accelerate the development of AI tools, epidemiological studies, and public health strategies in PVC. Its implementation will require pilot testing, strategic partnerships, and a focus on interoperability with existing systems, ensuring a balance between accessibility and data protection. The results of this study were presented at the OPTOM 2024 Congress.



Chapter 6. Development of artificial intelligence models in primary visual care

AI has experienced remarkable growth in the field of visual health, with increasingly broad applications in the detection and management of visual dysfunctions and ocular pathologies, although its use in PVC remains limited. This chapter aimed to develop three predictive AI models trained with optometric clinical data to support decision-making in PVC.

A database was structured from 1,125 clinical records collected between 2012 and 2021 at a university optometry clinic, under ethical authorization, generating 2,240 individual entries and 214 fields organized into clinical groups. The data were preprocessed, transformed, and encoded to ensure consistency, resulting in a dataset with categorical and binary variables. The information was classified into groups such as anamnesis, family history, oculomotor tests, ocular examinations, and clinical decisions. Three models were defined: M1 (case classification), M2 (affected ocular segment), and M3 (binocular vision dysfunction). Each model was trained using five multiclass classification algorithms (Random Forest, Decision Tree, Neural Network, Support Vector Machine, and Logistic Regression), evaluating four versions of the data generated through balancing techniques (SMOTE) and with normalized data.

In the training phase, Random Forest (RF) stood out as the algorithm with the best performance. In M1, RF achieved an average accuracy of 95.7%, outperforming Decision Tree (90.1%). In M2, RF obtained 98.2% compared to 97.1% for Neural Network, and in M3, RF reached 99.7%, surpassing NN (97.5%). Five-fold cross-validation confirmed the robustness of the models, showing consistency in metrics such as precision, sensitivity, F1 score, and specificity. Key variables recurrent across the three models were identified, including age, visual acuity, and symptoms such as ocular pain, burning sensation, and complaints of near or distance vision.

These models exemplify how AI can support professionals in PVC contexts, with high potential to optimize screening, referral, and initial case management processes. However, the need for additional multicentre validations and addressing technical challenges associated with the clinical use of AI - such as algorithm transparency and sensitive data management - is recognized. This work marks the first step toward developing the VA that can expand access to visual care.

The results of this study were published in *Ophthalmic and Physiological Optics* (2025) and were preliminarily presented as an oral communication at the 28th International Congress of Optometry, Contactology, and Ophthalmic Optics (OPTOM 2024).



Chapter 7. Development of the virtual assistant prototype in primary visual care

The growing demand for digital solutions in visual health has driven the development of VAs as tools to support clinical and educational decision-making. This chapter describes the design and implementation of a web application called VICH (*Vision Care Helper Intelligence*), conceived to integrate the predictive AI models developed in Chapter 6 and facilitate their practical use in PVC.


The development process followed four stages: planning and structuring, design and prototyping, development and integration, and internal testing. A hybrid client-server architecture was defined, complemented by cloud computing through Google Cloud, enabling the execution of previously developed AI models. Programming combined ASP.NET (Visual Basic) for the server, JavaScript (jQuery) for the client, and Python (Flask) to manage the connection with the AI models. Three functional modules were implemented: “Find Model”, “Consultation Panel” and “Result”. The interface was designed as a single-page application (SPA), responsive and multilingual (Spanish, English, and Portuguese), with special attention to usability and accessibility.

In the “Find Model” module, users can locate available models through a basic chatbot or a dropdown menu. The “Consultation Panel” allows the input of minimum and complementary clinical data, applying internal semantic modulation processes to adapt clinical terms to the inputs

required by the trained models. The integration ensures the secure sending and receiving of data in the cloud, presenting the results in the “Result” module in a user-friendly manner, including associated statistics on model reliability and prediction probabilities.

The tests conducted verified the stability, compatibility, and ease of use of the application across different devices and browsers. This development represents a significant advance by transferring the AI models into a real-world application context, strengthening their potential as a support tool for both visual health professionals and students in training. Its modular and multilingual design, together with cloud infrastructure integration, ensures scalability and accessibility.

The preliminary results of this study were presented at the *VI Pre-Doctoral Researchers Conference of UVa in Vision Sciences* in 2022 (awarded best presentation) and made available in open access through the official website (<https://www.visioncare.digital/vichi>). The VICH assistant was also included in a publication in *Ophthalmic and Physiological Optics* (2025) and in an oral communication at the international OPTOM 2024 Congress, both highlighted in the dissemination of Chapter 6.



Chapter 8. Validation of an artificial intelligence assistant to support decision-making in visual and ocular health

AI has established itself as an innovative tool in healthcare, with increasingly relevant applications in the detection and management of diseases, particularly ocular and visual conditions. However, its implementation raises challenges related to professional trust, transparency, and the acceptance of new technologies. This chapter evaluated the impact of the VA VICH, presented in Chapters 6 and 7, on diagnostic accuracy and on visual health professionals' perceptions of using AI in their practice.

A quantitative, comparative study was designed and approved by the Ethics Committee, using an online questionnaire available in three languages (Spanish, English, and Portuguese). A total of 310 professionals from 12 countries participated, mainly optometrists (82.6%), with a mean age of 43.2 years. Participants were randomly assigned to an intervention group (IG), exposed to the VA's predictions, or a control group (CG), without exposure. The questionnaire included six clinical cases, questions about confidence level, and perceptions/opinions regarding AI. Omission rates, concordance, and similarity with the VA were analysed using Chi-square tests and mean comparisons.

The results showed that the IG exhibited greater concordance with the VA in all clinical cases, with statistically significant differences in cases

A, E, and F ($P<0.01$). Overall concordance was 40.5% in the IG compared to 31.8% in the CG ($P<0.001$), while similarity reached 67.2% versus 57.1% ($P<0.05$). Omission rates were lower in the IG (4.2%) than in the CG (8.6%, $P=0.011$). Subgroups of professionals with more than 15 years of experience and those residing in the Americas demonstrated higher concordance with the VA ($P<0.01$).

In terms of confidence, participants who aligned with the VA's recommendations reported greater self-confidence, especially in case E ($P=0.037$). However, in case F, the mean confidence was slightly lower in the IG (3.5) compared to the CG (3.7), suggesting that exposure to probabilistic predictions may generate some uncertainty when the recommendation differs from professional judgment.

Regarding overall perception, 73.7% of participants expressed positive feelings about the future of AI in visual health, with “motivation” (20.4%) and “optimism” (17.1%) being the most frequent. The perceived usefulness of the VA was rated at a mean of 3.9/5, while confidence in AI-based technologies reached 3.5/5, reflecting good acceptance.

These findings highlight the potential of VAs to improve diagnostic coherence and reduce clinical indecision, though they also underscore the need for additional strategies and validations to ensure safe integration into visual care. Preliminary results of this study were presented at the 1st National Optometry Seminar of Universidade do Contestado (Brazil, 2025).



Chapter 9. Challenges and future lines

The Doctoral Thesis faced significant challenges related to the collection and access to optometric clinical data, given the low level of digitalization in systems and the need to work with printed records. This limited standardization and reduced the volume of information available for building robust models. The multidisciplinary and innovative nature of the study demanded a progressive process of technical and methodological development in a field still emerging for the research group. Additionally, the lack of a strong research tradition in optometry in Brazil and the geographical distance from the main research team required a high degree of self-management, partially mitigated by the support of the supervisor, virtual seminars, and an international research stay in the United Kingdom. The COVID-19 pandemic also impacted the planning and execution of various phases of the project.

While specific limitations and perspectives were addressed in each chapter, particular emphasis is placed on the need for larger, multicentre databases to improve the generalizability of predictive models (Chapter 6), as well as the validation of the VA in real clinical settings to consolidate its utility and professional acceptance (Chapter 8). Challenges were also identified regarding data standardization and the integration of digital technologies in resource-limited contexts, along with technical issues such as the transparency of AI algorithms and reliance on external infrastructures for their execution.

Despite these challenges, the achievements of this thesis lay the groundwork for future research. Among the most promising directions are the expansion of AI models to new visual conditions, including the management of dry eye using data worked on during the research stay at Aston University, as well as the implementation of the proposed clinical data storage platform and the development of advanced versions of the VA with integration of natural language models and mobile functionalities. These actions will strengthen its clinical and educational applicability, contributing to enhanced support and access in PVC.



Chapter 10. Conclusions

General: An AI-based VA was developed through the integration of predictive models trained with optometric clinical data and oriented toward screening. Its implementation in an accessible and functional application enabled the generation of recommendations capable of supporting clinical decision-making in PVC by professionals in the field.

1. Digital technologies applied to vision sciences over the past decade are concentrated in AI, particularly in deep learning techniques, with a predominance of studies focused on posterior segment diseases. Scientific production is largely oriented toward specialized clinical support, with limited representation of topics related to PVC, revealing a gap and relatively unexplored potential for the development of digital solutions aimed at this level of care.

2. Publicly available datasets in vision sciences exhibit a thematic concentration in specialized clinical areas, particularly the retina and surgery, with poorly standardized formats and scarce representation of data related to PVC. This situation highlights a heterogeneous and limited availability relative to current needs for access, diversity, and applicability in research projects targeting visual healthcare.

3. A global platform for the storage of clinical data in visual health has been proposed, integrating established EHR standards and features of existing repositories. This conceptual model is oriented toward

optometry and PVC and aims to structure, protect, and share clinical data ethically and efficiently for both scientific and healthcare purposes.

4. Three AI models have been generated, trained with structured optometric clinical data, enabling high-accuracy predictions for case classification, localization of ocular problems, and detection of binocular vision dysfunctions based on signs and symptoms, thus offering support for decision-making in PVC.

5. A web application in the form of a VA has been developed, integrating AI models trained with optometric clinical data. It is structured into functional modules connected to the cloud, allowing predictions to be executed in an accessible, secure, and understandable way, facilitating its application both in PVC clinical practice and educational settings.

6. The influence of the VA on decision-making was evaluated, showing that its recommendations have a positive impact by increasing concordance and reducing omissions in professionals' responses. The general perception of professionals is favourable regarding its utility, although moderate levels of confidence were observed, reflecting the need to strengthen familiarization and transparency in the use of AI-based tools in visual health.

Sesión
Session



RESUMEN

Summary in Spanish



Capítulo 1. Introducción

La presente Tesis Doctoral se sitúa entre diferentes campos del conocimiento, integrando salud visual, salud digital e inteligencia artificial (IA) en un marco conceptual coherente e interdisciplinar.

Atención primaria en salud visual: La atención visual primaria (AVP) representa un pilar estratégico para la detección precoz y el manejo oportuno de alteraciones oculares que, en su mayoría, son prevenibles o tratables si se abordan a tiempo. Sin embargo, en muchos contextos, su efectividad se ve comprometida por la falta de recursos humanos y tecnológicos, así como por la ausencia de protocolos estandarizados y una formación insuficiente del personal. Frente a estos desafíos, la integración de tecnologías digitales y soluciones basadas en inteligencia artificial, junto con modelos colaborativos y telesalud, ha demostrado ser una vía prometedora para mejorar el acceso, precisión diagnóstica y eficiencia asistencial, fortaleciendo así la capacidad resolutive de la atención ocular en su nivel más próximo a la comunidad.

Transformaciones digitales en salud: La transformación digital en salud ha dejado de ser una simple incorporación de tecnologías aisladas y se ha convertido en una reconfiguración estructural del modelo asistencial, integrando herramientas digitales en todas las etapas del cuidado, desde la prevención hasta el seguimiento. Este proceso se ha acelerado tras la pandemia de COVID-19, que impulsó el uso masivo de

soluciones como la *eHealth*, *mHealth*, telemedicina, Internet de las Cosas y dispositivos vestibles, cada una con aplicaciones específicas para mejorar la accesibilidad, agilizar procesos y fortalecer la continuidad del cuidado. En el ámbito de la salud visual, estas tecnologías han permitido desarrollar herramientas de autoevaluación, monitoreo remoto, cribado y sistemas de análisis de imágenes, entre otros. No obstante, su adopción enfrenta barreras relacionadas con la variabilidad en la calidad de las herramientas y los desafíos éticos que plantea la automatización. En este contexto, los sistemas de apoyo a la decisión clínica se destacan como recursos para fortalecer la práctica profesional y mejorar la precisión diagnóstica.

Datos clínicos como base para la innovación: En el marco del concepto de *Big Data*, el crecimiento de los datos clínicos electrónicos ha transformado estos registros en un recurso estratégico para la innovación en salud, posibilitando el desarrollo de soluciones basadas en IA y mejorando la gestión de servicios. Esta expansión, impulsada por tecnologías digitales, se apoya en infraestructuras como los Registros Electrónicos de Salud (RES) y repositorios integrados, que permiten consolidar información de múltiples fuentes en entornos seguros y reutilizables. No obstante, persisten desafíos importantes, como la falta de estandarización, problemas de interoperabilidad y barreras éticas vinculadas a la privacidad, consentimiento y uso responsable de los datos. A pesar de ello, los datos organizados y accesibles bajo marcos éticos pueden contribuir al desarrollo de soluciones, desde el análisis de tendencias poblacionales hasta el diseño de intervenciones personalizadas, permitiendo una atención más predictiva, eficiente y centrada en las personas.

Asistentes virtuales en el ámbito de la salud: El asistente virtual (AsV), concebido como una herramienta digital capaz de interactuar mediante lenguaje natural, ha dado lugar a múltiples aplicaciones en el ámbito sanitario gracias al avance de la IA y a la expansión de plataformas accesibles. Así, los AsV han extendido su uso desde funciones administrativas hasta el cribado, el seguimiento de enfermedades crónicas y la educación en salud. Aunque su aplicación en salud visual aún es incipiente, existen iniciativas prometedoras en orientación básica y apoyo al paciente, lo que refuerza su potencial como recurso estratégico para mejorar el acceso, facilitar la comunicación y apoyar decisiones de forma complementaria.

Inteligencia artificial y sus aplicaciones en salud: La IA se refiere al desarrollo de sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el reconocimiento de patrones, el aprendizaje o la toma de decisiones. Su funcionamiento se basa en modelos entrenados mediante algoritmos de *Machine Learning* (ML) y *Deep Learning* (DL), que procesan datos y generan salidas como predicciones o clasificaciones. Estos modelos pueden desarrollarse bajo distintas modalidades de aprendizaje y abarcar tareas que van desde clasificar imágenes médicas hasta generar lenguaje. Comprender sus principios permite interpretar con mayor claridad su aplicación en los distintos contextos.

En el ámbito sanitario, la IA ha demostrado un enorme potencial para transformar procesos asistenciales, gracias a su capacidad para analizar grandes volúmenes de datos clínicos, identificar patrones complejos y generar recomendaciones útiles para el cuidado del paciente. Desde herramientas de cribado automatizado y análisis de

imágenes hasta modelos predictivos de respuesta terapéutica, su integración en distintas especialidades en salud ha ampliado las posibilidades diagnósticas y mejorado la eficiencia operativa. En lugar de reemplazar al profesional, actúa como un apoyo complementario que optimiza el proceso de toma de decisiones clínicas, especialmente útil en contextos con alta demanda o recursos limitados. Sin embargo, también plantea desafíos, como riesgo de sesgos, privacidad de los datos y interpretación de resultados en modelos complejos. Así, la comprensión crítica de sus aplicaciones y limitaciones es fundamental para garantizar una implementación segura, responsable y eficaz.

IA en salud visual: Este bloque presentó un estado del arte en estos campos, subrayando que la salud visual ha emergido como uno de los entornos más fértiles para la aplicación de IA, impulsado por la abundancia de datos visuales, la estandarización diagnóstica y el avance en tecnologías de imagen. Modelos basados en DL han sido ampliamente aplicados al análisis de retinografías, tomografía de coherencia óptica (OCT) y topografías corneales, con resultados que igualan o superan la precisión del examen clínico convencional en patologías como la retinopatía diabética, glaucoma o queratocono. Estas herramientas permiten desde cribados poblacionales hasta apoyo en cirugías o planificación refractiva, ampliando el acceso y mejorando la eficiencia clínica. Más allá de las aplicaciones diagnósticas, se exploran usos en educación, asistencia a personas con baja visión y generación automatizada de recomendaciones. Como línea emergente, el concepto de *oculomics* propone utilizar el análisis ocular como vía para la detección de enfermedades sistémicas, mediante algoritmos que procesan imágenes de retina para identificar biomarcadores de riesgo cardiovascular, envejecimiento biológico o deterioro cognitivo.



Capítulo 2. Fundamentación y planteamiento general

Justificación: La AVP desempeña un papel estratégico en la prevención de deficiencias visuales y en la mejora del acceso a los cuidados oculares. Por otro lado, enfrenta limitaciones derivadas de la escasez de profesionales, desigualdades territoriales y una demanda creciente. En este contexto, la integración de tecnologías digitales, especialmente la IA, emerge como una solución prometedora. La IA ha demostrado gran potencial en tareas clínicas como el análisis de imágenes y la clasificación de patologías, aunque su aplicación en entornos accesibles y dirigidos a la optometría sigue siendo limitada. Esta tesis propone desarrollar un AsV basado en IA que articule datos clínicos, tecnología y conocimientos en salud visual para apoyar la toma de decisiones en AVP, una propuesta que se justifica en tres pilares: la relevancia de la problemática, la oportunidad tecnológica actual y la viabilidad operativa para generar una solución útil y escalable.

Hipótesis: El desarrollo de un AsV basado en modelos de IA, entrenado con datos clínicos específicos, puede constituir una herramienta pertinente y factible para apoyar la toma de decisiones en AVP, a partir del análisis de signos, síntomas y resultados de exámenes clínicos.

Objetivo General: Desarrollar y validar un AsV basado en IA para apoyar la toma de decisiones en AVP.

Objetivos específicos:

1. Analizar el desarrollo de la investigación en salud digital aplicada a las ciencias de la visión, caracterizando su relación con la atención visual y describiendo las tecnologías propuestas en este ámbito.
2. Analizar la disponibilidad y características de los conjuntos de datos públicos relacionados con las ciencias de la visión.
3. Proponer un modelo de plataforma global para el almacenamiento de datos clínicos, basado en estándares de RES y modelos actuales de repositorios.
4. Generar modelos de IA entrenados con datos clínicos optométricos, orientados a apoyar la toma de decisiones en AVP.
5. Desarrollar una aplicación en formato de AsV que integre modelos de IA, facilitando su aplicación en contextos clínicos y educativos.
6. Evaluar la influencia del AsV en la toma de decisiones clínicas en salud visual, así como la percepción de los profesionales sobre su uso.

Metodología general: La tesis se organiza en dos bloques complementarios para alcanzar todos los objetivos. El primero, de carácter exploratorio, abarca la revisión de tecnologías digitales en salud visual (1), la disponibilidad de datos (2) y la propuesta de una plataforma de almacenamiento (3). El segundo se centra en el desarrollo y validación del AsV (4, 5 y 6), incluyendo la generación de modelos predictivos, creación de la aplicación y evaluación de su impacto. Cada capítulo aplica metodologías específicas según las necesidades del objetivo correspondiente, integrándose en una lógica progresiva orientada al cumplimiento del objetivo general.



Capítulo 3. Caracterización de tecnologías en salud digital aplicadas en el cuidado de la visión

La salud digital ha transformado el cuidado de la visión, introduciendo tecnologías que optimizan el diagnóstico, gestión y la atención de enfermedades oculares. Este capítulo tuvo como objetivo analizar la producción científica sobre tecnologías digitales aplicadas a la salud de la visión entre 2012 y 2021.

Se realizó una revisión exploratoria en SCOPUS con artículos en inglés publicados en revistas científicas de salud y computación. La búsqueda empleó términos relacionados con salud visual y tecnologías como IA, *big data*, realidad virtual y telesalud, considerando publicaciones de la última década. Tras aplicar criterios de inclusión y exclusión, se identificaron 1069 artículos para el análisis, los cuales fueron clasificados según la tecnología utilizada, las estructuras oculares o condiciones abordadas y el tipo de aplicación propuesta.

Los resultados mostraron un crecimiento sostenido de publicaciones, con el 84,4% de los estudios publicados entre 2017 y 2021. La IA destacó como la tecnología más utilizada (77,7%), especialmente mediante DL para el análisis de imágenes, seguida de eHealth (68,6%) y mHealth (60,9%). *Big data* apareció en el 13,7% de los trabajos y otras tecnologías, como realidad virtual y aumentada, tuvieron menor representación. La mayoría de los estudios procedía de Asia y América del Norte, con liderazgo de Estados Unidos, China e India, mientras que

Europa, Oceanía, África y América Latina presentaron contribuciones más limitadas.

En relación con la salud ocular, la retina fue la estructura más analizada (93,3% de los estudios sobre polo posterior), centrada en enfermedades como la retinopatía diabética y el glaucoma. El polo anterior recibió menor atención (10,9%), al igual que la vía visual (3,9%). Aproximadamente un cuarto de los artículos no identificó claramente la estructura ocular evaluada y un tercio no especificó la condición visual tratada. Las aplicaciones clínicas predominaron (93,7%), principalmente para apoyar el diagnóstico, análisis y clasificación, mientras que solo el 15,2% de los estudios incluyeron aplicaciones dirigidas a la AVP. En el ámbito no clínico, se destacaron la estandarización, telemedicina y la gestión de datos como áreas emergentes.

Estos resultados evidencian una concentración en tecnologías avanzadas orientadas a la atención secundaria y terciaria, con un marcado enfoque en la retina como estructura predominante de estudio, mientras que las herramientas para fortalecer la atención primaria en salud visual siguen siendo limitadas. Este capítulo fue publicado en la edición especial “Artificial Intelligence, Data Science and E-health in Vision Research and Clinical Activity” del Journal of Optometry (2022), y sus resultados preliminares se presentaron en el 26º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica (OPTOM, 2021 - versión online).



Capítulo 4. Disponibilidad y características de conjuntos de datos clínicos para uso las ciencias de la visión

El acceso a conjuntos de datos clínicos es esencial para impulsar la investigación y el desarrollo tecnológico en salud visual, permitiendo analizar grandes volúmenes de información de forma rápida y viable. En el ámbito de las ciencias de la visión, estos recursos posibilitan estudios epidemiológicos y la construcción de algoritmos de IA aplicados al diagnóstico y tratamiento de enfermedades oculares. Este capítulo tuvo como objetivo explorar la disponibilidad pública de conjuntos de datos relacionados con salud visual.

Se llevó a cabo una búsqueda sistemática en Google Data Set Search entre enero de 2019 y septiembre de 2021, utilizando los términos “optometry”, “ophthalmology” y “eye care”. La selección incluyó únicamente datos accesibles públicamente y vinculados con salud ocular. Tras excluir 28 duplicados y 42 conjuntos irrelevantes, se analizaron 362 conjuntos de datos. Estos fueron clasificados por formato, fuente, accesibilidad, perfil temático, nivel de atención y relación con estructuras o patologías oculares. El análisis utilizó un enfoque cuantitativo para describir tendencias y patrones.

Los resultados mostraron que el 44,2% de los conjuntos se localizaron con el término “*ophthalmology*”, el 43,6% con “*eye care*” y apenas el 12,2% con “*optometry*”. La mayoría presentaba acceso libre (64,1%) y los formatos más comunes fueron tabla (52,2%), documento (24,6%) e

imagen (12,4%), mientras un 30,4% se clasificó como “otros”, lo que refleja una diversidad de estructuras que puede dificultar su uso estandarizado. Las principales fuentes identificadas fueron [statista.com](https://www.statista.com), con 127 conjuntos, seguida de data.mendeley.com y [figshare.com](https://www.figshare.com), aunque la ausencia de repositorios especializados en ciencias de la visión destaca como una limitación.

En cuanto al perfil temático, el 46,1% de los datos se relacionaba con salud y el 26,2% tenía contenido clínico. Los datos clínicos se concentraron mayoritariamente en el segundo (58%) y tercer nivel de atención (27%), mientras solo un 15% estaba vinculado a atención primaria visual. Las áreas más representadas fueron retina (19,8%), exámenes generales (15,6%), polo anterior (13,5%) y cirugía (11,5%). Por el contrario, temas como refracción, baja visión, lentes oftálmicas y ambliopía apenas alcanzaron el 1% cada uno. Esta distribución evidencia un enfoque hacia contextos especializados, con carencias significativas en recursos aplicables a la AVP.

Estos hallazgos subrayan la necesidad de desarrollar plataformas específicas y estrategias de estandarización que amplíen el acceso y optimicen el uso de datos en investigaciones y desarrollos tecnológicos en ciencias de la visión, especialmente considerando que la mayoría de los conjuntos clínicos identificados se centran en la retina y el polo posterior, dejando vacíos significativos en otras áreas. Los resultados de este estudio fueron presentados en el Congreso OPTOM 2022.



Capítulo 5. Propuesta de plataforma *big data* para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular

El almacenamiento y gestión de datos clínicos son elementos estratégicos para impulsar la investigación y la innovación tecnológica en salud. Este capítulo propone una plataforma global para optometría, desarrollada a partir de una revisión de estándares en RES y modelos actuales de repositorios en ciencias de la visión. Esta propuesta se justifica como respuesta a los hallazgos de los capítulos anteriores, especialmente a las brechas identificadas en la disponibilidad de datos clínicos para la salud ocular en el Capítulo 4.

El estudio se realizó en tres etapas. Primero, se revisaron normas y directrices para RES mediante una búsqueda en PubMed que identificó 7 artículos relevantes de 2019-2023. Se extrajeron 24 elementos clasificados en cuatro categorías: interoperabilidad (45,8%), accesibilidad (29,1%), seguridad (54,1%) y privacidad (12,5%). Entre los estándares destacados se encontraron HL7, FHIR, DICOM, PACS y protocolos de seguridad como SSL/TLS, así como políticas de anonimización y normativas como el GDPR.

En la segunda etapa se identificaron 13 plataformas de repositorios de datos en salud ocular, de las cuales solo cinco contaban con publicaciones científicas asociadas. La plataforma IRIS, gestionada por la American Academy of Ophthalmology, concentró el 43% de las

publicaciones (82 referencias), seguida por FRB! (28,3%) e INSIGHT (20,9%). Sin embargo, la mayoría de estos sistemas tiene un enfoque especializado en enfermedades del segmento posterior, dejando sin cubrir áreas clave de la optometría y la AVP. Iniciativas recientes como UK Eye Care Data Hub y Optometry 2040 indican una tendencia hacia soluciones más amplias y accesibles, orientadas a este campo.

La tercera etapa integró estos hallazgos en el diseño conceptual de DAVIH (Data Vision Health), una plataforma propuesta para la recopilación, almacenamiento y análisis de datos en salud visual. Está estructurada en módulos que incluyen “entradas” desde RES y aplicaciones clínicas, almacenamiento seguro en la nube, y “salidas” para acceso por investigadores y profesionales autorizados. Los protocolos implementados garantizan interoperabilidad, seguridad y privacidad, mientras que su modelo de gobernanza considera un consorcio internacional para facilitar su desarrollo global.

La propuesta responde a la necesidad de superar la fragmentación de datos, en especial en optometría, y podría acelerar el desarrollo de herramientas de IA, estudios epidemiológicos y estrategias de salud pública en AVP. Su implementación requerirá pruebas piloto, alianzas estratégicas y un enfoque en la interoperabilidad con sistemas existentes, asegurando un equilibrio entre accesibilidad y protección de datos. Los resultados de este estudio fueron presentados en el Congreso OPTOM 2024.



Capítulo 6. Desarrollo de modelos de inteligencia artificial en atención visual primaria

La IA ha experimentado un notable crecimiento en el campo de la salud visual, con aplicaciones cada vez más amplias en la detección y el manejo de disfunciones visuales y patologías oculares, aunque su uso en la atención primaria sigue siendo limitado. Este capítulo tiene como objetivo desarrollar tres modelos predictivos de IA, entrenados con datos clínicos optométricos, para apoyar la toma de decisiones en la AVP.

Se estructuró una base de datos a partir de 1.125 fichas clínicas recolectadas entre 2012 y 2021 en una clínica universitaria de Optometría, mediante autorización ética, generando 2.240 registros individuales y 214 campos organizados en grupos clínicos. Los datos fueron preprocesados, siendo transformados y codificados para asegurar la consistencia, lo que resultó en un conjunto con variables categóricas y binarias. La información se clasificó en grupos como anamnesis, historial familiar, pruebas oculomotoras, exploraciones oculares y decisiones clínicas. Se definieron tres modelos: M1 (clasificación del caso), M2 (segmento ocular afectado) y M3 (disfunción de visión binocular). Cada modelo fue entrenado utilizando cinco algoritmos de clasificación multiclase (Random Forest, Decision Tree, Neural Network, Support Vector Machine y Logistic Regression),

evaluando cuatro versiones de los datos generadas mediante técnicas de balanceo (SMOTE) y con datos normalizados.

En la fase de entrenamiento, Random Forest (RF) destacó como el algoritmo con mejor rendimiento. En M1, RF alcanzó una exactitud promedio del 95,7%, superior a Decision Tree (90,1%). En M2, RF obtuvo un 98,2% frente al 97,1% de Neural Network, y en M3, RF logró un 99,7%, superando a NN (97,5%). La validación cruzada en cinco iteraciones confirmó la robustez de los modelos, mostrando consistencia en métricas como precisión, sensibilidad, índice F1 y especificidad. Se identificaron variables claves recurrentes en los tres modelos, entre ellas la edad, la agudeza visual y síntomas como dolor ocular, ardor y quejas de visión cercana o lejana.

Estos modelos constituyen ejemplos de cómo la IA puede servir de apoyo a los profesionales en contextos de AVP, con un alto potencial para optimizar los procesos de cribado, derivación y manejo inicial de casos. Sin embargo, se reconoce la necesidad de validaciones multicéntricas adicionales y de abordar retos técnicos asociados al uso clínico de IA, como la transparencia de los algoritmos y la gestión de datos sensibles. Este trabajo marca el primer paso hacia el desarrollo del AsV que pueda ampliar el acceso al cuidado visual.

Los resultados de este estudio fueron publicados en la revista *Ophthalmic and Physiological Optics* (2025) y presentados preliminarmente en formato de comunicación oral en el 28º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica (OPTOM 2024).



Capítulo 7. Desarrollo del prototipo del asistente virtual en atención visual primaria

La creciente demanda de soluciones digitales en salud visual ha impulsado el desarrollo de AsV como herramientas de apoyo en la toma de decisiones clínicas y educativas. Este capítulo describe el diseño y la implementación de una aplicación web denominada VICHÍ (Vision Care Helper Intelligence), concebida para integrar los modelos predictivos de IA desarrollados en el Capítulo 6 y facilitar su uso práctico en la AVP.

El proceso de desarrollo siguió cuatro etapas: planificación y estructuración, diseño y prototipado, desarrollo e integración, y pruebas internas. Se definió una arquitectura híbrida cliente-servidor, complementada con computación en la nube mediante Google Cloud, permitiendo la ejecución de modelos de IA previamente desarrollado. La programación combinó ASP.NET (Visual Basic) para el servidor, JavaScript (jQuery) para el cliente y Python (Flask) para gestionar la conexión con los modelos IA. Se implementaron tres módulos funcionales: “Encontrar modelo”, “Panel de consulta” y “Resultado”. La interfaz fue diseñada como una aplicación de página única (SPA), responsiva y multilingüe (español, inglés y portugués), con especial atención a la usabilidad y accesibilidad.

En el módulo “Encontrar modelo”, el usuario puede localizar modelos disponibles mediante un chatbot básico o un menú desplegable. El

“Panel de consulta” permite la introducción de datos clínicos mínimos y complementarios, aplicando procesos internos de modulación semántica para adaptar los términos clínicos a las entradas requeridas por los modelos entrenados. La integración asegura el envío y la recepción de datos en la nube, presentando los resultados en el módulo “Resultado” de forma comprensible, con estadísticas asociadas sobre la fiabilidad del modelo y las probabilidades de predicción.

Las pruebas realizadas verificaron la estabilidad, compatibilidad y facilidad de uso de la aplicación en diferentes dispositivos y navegadores. Este desarrollo representa un avance significativo al trasladar los modelos de IA a un contexto real de aplicación, fortaleciendo su potencial como herramienta de apoyo tanto para profesionales de la salud visual como para estudiantes en formación. Su diseño modular y multilingüe, junto con la integración con infraestructura en la nube, garantiza escalabilidad y accesibilidad.

Los resultados preliminares de este estudio fueron presentados en la VI Jornada de Investigadores Predoctorales de la UVA en Ciencias de la Visión en 2022 (premio a la mejor presentación), así como puestos a disposición en acceso abierto a través del sitio web oficial (<https://www.visioncare.digital/vichi>). El asistente VICHÍ también fue incluido en una publicación en *Ophthalmic and Physiological Optics* (2025) y en una comunicación oral en el congreso internacional OPTOM 2024, ambos destacados en la difusión del Capítulo 6.



Capítulo 8. Validación de modelos de inteligencia artificial para apoyar la toma de decisiones en salud visual y ocular

La IA se ha consolidado como una herramienta innovadora en el ámbito de la salud, con aplicaciones cada vez más relevantes en la detección y manejo de enfermedades, en especial las oculares y visuales. Sin embargo, su implementación plantea desafíos relacionados con la confianza profesional, transparencia y la aceptación de nuevas tecnologías. Este capítulo evaluó el impacto del AsV VICHÍ, presentado en los Capítulos 6 y 7, en la precisión diagnóstica y en la percepción de profesionales de la salud visual sobre el uso de IA en su práctica.

Se diseñó un estudio cuantitativo y comparativo, aprobado por el Comité de Ética, utilizando un cuestionario online disponible en tres idiomas (español, inglés y portugués). Participaron 310 profesionales de 12 países, principalmente ópticos-optometristas (82,6%), con una edad media de 43,2 años. Los participantes fueron asignados aleatoriamente a un grupo intervención (GI), expuesto a las predicciones del AsV, o a un grupo control (GC), sin exposición. El cuestionario incluyó seis casos clínicos, preguntas sobre nivel de confianza y percepción/opinión sobre la IA. Se analizaron tasas de omisión, concordancia y similitud con el AsV, aplicando pruebas Chi-cuadrado y comparación de medias.

Los resultados mostraron que el GI presentó una mayor concordancia con el AsV en todos los casos clínicos, con diferencias estadísticamente significativas en los casos A, E y F ($P < 0,01$). La concordancia global fue

del 40,5% en el GI frente al 31,8% en el GC ($P<0,001$), mientras la similitud alcanzó el 67,2% contra 57,1% ($P<0,05$). Las omisiones fueron menores en el GI (4,2%) que en el GC (8,6%, $P=0,011$). Subgrupos de profesionales con más de 15 años de experiencia y residentes en América presentaron una mayor concordancia con el AsV ($P<0,01$).

En términos de confianza, los participantes que coincidieron con las recomendaciones del AsV reportaron mayor autoconfianza, especialmente en el caso E ($P=0,037$). Sin embargo, en el caso F, la confianza media fue ligeramente inferior en el GI (3,5) en comparación con el GC (3,7), lo que sugiere que la exposición a predicciones probabilísticas puede generar cierta incertidumbre cuando la recomendación difiere del juicio profesional.

Respecto a la percepción general, el 73,7% de los participantes manifestó sentimientos positivos sobre el futuro de la IA en salud visual, destacando “motivación” (20,4%) y “optimismo” (17,1%) como los más frecuentes. La utilidad percibida del AsV fue evaluada con una media de 3,9/5, mientras que la confianza en tecnologías basadas en IA alcanzó 3,5/5, reflejando una buena aceptación.

Estos hallazgos destacan el potencial de los AsV para mejorar la coherencia diagnóstica y reducir la indecisión clínica, aunque subrayan la necesidad de estrategias y validaciones adicionales para garantizar una integración segura en la atención visual. Resultados preliminares de este estudio fueron presentados en el 1er Seminario Nacional de Optometría de la Universidad del Contestado (Brasil, 2025).



Capítulo 9. Desafíos y líneas futuras

La Tesis Doctoral enfrentó importantes desafíos relacionados con la recolección y el acceso a datos clínicos optométricos, dados los sistemas poco digitalizados y la necesidad de trabajar con registros impresos, lo que limitó la estandarización y redujo el volumen de información para la construcción de modelos robustos. La naturaleza multidisciplinar y novedosa del estudio exigió un proceso progresivo de desarrollo técnico y metodológico en un campo aún incipiente para el grupo investigador. Asimismo, la falta de tradición investigadora en Optometría en Brasil y la distancia geográfica con el equipo de investigación principal impusieron un alto grado de autogestión, mitigado en parte por el acompañamiento del director, seminarios virtuales y una estancia internacional en el Reino Unido. La pandemia de COVID-19 también impactó la planificación y ejecución de diversas fases del proyecto.

Si bien las limitaciones y perspectivas específicas fueron abordadas en cada capítulo, se destacan especialmente aquellas relacionadas con la necesidad de bases de datos más amplias y multicéntricas para mejorar la generalización de los modelos predictivos (Capítulo 6), así como la validación del AsV en entornos clínicos reales para consolidar su utilidad y aceptación profesional (Capítulo 8). También se identificaron retos vinculados a la estandarización de datos y la integración de tecnologías digitales en contextos con recursos limitados, junto con desafíos

técnicos como la transparencia de los algoritmos de IA y la dependencia de infraestructuras externas para su ejecución.

A pesar de estos retos, los logros alcanzados sientan las bases para futuras investigaciones. Entre las líneas más prometedoras se encuentra la expansión de los modelos de IA a nuevas condiciones visuales, incluyendo el manejo del ojo seco mediante datos trabajados durante la estancia en Aston University, así como la implementación de la plataforma de almacenamiento de datos clínicos propuesta y el desarrollo de versiones avanzadas del AsV con integración de modelos de lenguaje natural y funcionalidades móviles. Estas acciones permitirán fortalecer su aplicabilidad clínica y educativa, contribuyendo a reforzar y apoyar el acceso en la AVP.



Capítulo 10. Conclusiones

General. Se desarrolló un AsV basado en IA, mediante la integración de modelos predictivos entrenados con datos clínicos optométricos y orientados al cribado, cuya implementación en una aplicación accesible y funcional permitió generar recomendaciones capaces de apoyar la toma de decisiones clínicas en AVP por parte de profesionales del área.

1. Las tecnologías digitales aplicadas a las ciencias de la visión en la última década se concentran en IA, especialmente en técnicas de aprendizaje profundo, predominando estudios enfocados en enfermedades del polo posterior. La producción científica se orienta mayoritariamente al soporte clínico especializado, con baja representación de temáticas vinculadas a la AVP, lo que revela una brecha y un potencial relativamente poco explorado para el desarrollo de soluciones digitales orientadas a este nivel de atención.

2. Los conjuntos de datos públicos disponibles en las ciencias de la visión presentan una concentración temática en áreas clínicas especializadas, especialmente retina y cirugía, con formatos poco estandarizados y escasa representación de datos vinculados a la AVP. Esta situación evidencia una disponibilidad heterogénea y limitada frente a las necesidades actuales de acceso, diversidad y aplicabilidad en proyectos de investigación orientados a la atención sanitaria visual.

3. Se ha propuesto una plataforma global para el almacenamiento de datos clínicos en salud visual que integra los estándares consolidados de RES y características de repositorios existentes, incorporando principios como la interoperabilidad, la seguridad, la privacidad y la accesibilidad. El modelo conceptual está orientado a la optometría y a la AVP, y busca estructurar, proteger y compartir datos clínicos de forma ética y eficiente, con fines tanto científicos como asistenciales.

4. Se han generado tres modelos de IA entrenados con datos clínicos optométricos estructurados, que permiten predecir con alta exactitud la clasificación del caso, la localización del problema ocular y la presencia de disfunciones de la visión binocular a partir de signos y síntomas, ofreciendo soporte a la toma de decisiones en AVP.

5. Se ha desarrollado una aplicación web en formato de AsV que integra los modelos de IA entrenados con datos clínicos optométricos, estructurada en módulos funcionales conectados a la nube. Esta aplicación permite ejecutar predicciones de forma accesible, segura y comprensible, facilitando su aplicación tanto en la práctica clínica de AVP como en entornos educativos.

6. Se ha evaluado la influencia del AsV en la toma de decisiones encontrando que su recomendación muestra una influencia positiva en la toma de decisiones, al aumentar la concordancia y reducir las omisiones en las respuestas de los profesionales. La percepción general de los profesionales es favorable respecto a su utilidad, aunque se han detectado niveles moderados de confianza, lo que refleja la necesidad de fortalecer la familiarización y la transparencia en el uso de herramientas basadas en IA en el ámbito de la salud visual.

Capítulo
Chapter

1

Introducción

Introduction

La presente Tesis Doctoral se sitúa entre diferentes campos del conocimiento, integrando salud visual, salud digital e inteligencia artificial (IA) en un marco conceptual coherente e interdisciplinar. La introducción ha sido estructurada para guiar al lector a través de una secuencia lógica y progresiva de temas, que permita comprender las diferentes conexiones entre ellos y su relevancia en el desarrollo de la investigación llevada a cabo. Este recorrido temático se sintetiza en la Figura 1.0, que ilustra la trayectoria conceptual desarrollada a lo largo de la Introducción.




Figura 1.0. Flujo general de la organización del capítulo de introducción.



1.1. La salud visual y los desafíos en la atención primaria

La salud visual es parte integrante del bienestar general y su limitación puede afectar la calidad de vida, desde el rendimiento escolar, pasando por la productividad laboral, hasta una pérdida de independencia en la senectud. En este contexto, las políticas públicas orientadas a la atención visual primaria (AVP) son esenciales para detectar precozmente cualquier alteración visuo-motora u ocular, dado que muchas de estas condiciones tienen carácter progresivo y acumulativo. De esta forma, la detección temprana no solo permite reducir complicaciones, sino también implementar intervenciones más eficaces y menos costosas para el sistema de salud y para el propio paciente.^{1,2}

Es bien conocido que gran parte de las deficiencias visuales en el mundo son prevenibles o tratables mediante intervenciones tempranas y accesibles, de forma que los cuidados sanitarios en su nivel primario, por su cercanía a la comunidad y potencial resolutivo, representan un escenario clave para implementar estrategias de diagnóstico o manejo precoz. No obstante, en muchos entornos esta capacidad está limitada por factores como la escasez de personal capacitado, falta de acceso a servicios, carencia de instrumental y equipamiento clínico básico, o por la sobrecarga asistencial. En este contexto, el desarrollo de innovaciones y recursos tecnológicos accesibles y adaptados a la atención primaria visual puede convertirse en una herramienta útil para

ampliar la capacidad de detección, mejorar la precisión diagnóstica y disminuir los retrasos en la atención, a través de soluciones que no reemplacen a los profesionales sanitarios, sino que potencien su capacidad de actuación.^{3,4}

Se estima que al menos 2,2 mil millones de personas en el mundo tienen algún grado de discapacidad visual (Figura 1.1), y que la mitad de estos casos podría haberse detectado precozmente y tratado.¹ Los errores de refracción no corregidos y las cataratas no operadas son responsables de gran parte de esta carga global, aunque se observa también un crecimiento preocupante de afecciones crónicas como la retinopatía diabética o la degeneración macular, así como un aumento sostenido de la miopía, particularmente entre jóvenes.^{5,6} Estas condiciones suelen evolucionar silenciosamente, sin síntomas evidentes en etapas iniciales o sin complicaciones durante la juventud, de ahí la importancia del cribado y la vigilancia en el primer nivel de atención asistencial. Sin embargo, la falta de protocolos estandarizados y la limitada capacitación de algunos profesionales de la visión, dificultan una respuesta eficaz en algunos países o sistemas de salud, lo que provoca el subdiagnóstico, el retraso terapéutico o, también el exceso de derivaciones innecesarias a niveles especializados, lo que sobrecarga los sistemas de salud dificultando la atención, situación que también puede generar consecuencias clínicas similares a las del manejo tardío.⁶




Figura 1.1. Síntesis resumida del informe mundial sobre la visión de la Organización Mundial de la Salud. (CC BY-NC-SA 3.0 IGO)¹

1.1.1. Transformación digital en apoyo a AVP

Iniciativas como los centros de visión comunitarios en entornos urbanos y rurales de países en desarrollo, que combinan equipamiento básico, personal capacitado y conectividad para consultas remotas, han conseguido una reducción significativa en la prevalencia de ceguera y discapacidad visual.⁷ En esta misma línea, la combinación de tecnología con modelos colaborativos de atención, como los esquemas de cribado optométrico o el uso de la teleoftalmología, ha permitido no solo reducir los tiempos de espera y los errores diagnósticos, sino también optimizar el flujo de pacientes. Tecnologías basadas en inteligencia artificial (IA), como sistemas de clasificación de imágenes o herramientas de cribado integradas en dispositivos móviles, están siendo exploradas para apoyar la toma de decisiones clínicas en contextos de baja cobertura especializada.⁴ Por tanto, en este escenario, incorporar innovaciones tecnológicas y estrategias digitales en AVP, sin perder de vista la formación del personal, la equidad en el acceso y la sostenibilidad de los servicios, supone una alternativa concreta y necesaria para afrontar los desafíos actuales de la salud visual global.³

Más allá de la aplicación estrictamente ocular, estas iniciativas también pueden tener aplicaciones útiles sobre la salud general, ya que diferentes datos oculares pueden ser indicadores de otras condiciones sistémicas, cognitivas o psicosociales.⁸ Esto amplía la posibilidad de explorar la interacción ojo-cerebro-visión y su relación con otras enfermedades comunes en el nivel de atención primaria.^{9,10}

1.2. Transformaciones digitales en salud

El concepto de salud digital ha evolucionado más allá del simple uso de tecnologías de información y comunicación (TICs) dentro del entorno clínico y sanitario, y actualmente representa una transformación estructural en la forma en que se presta, organiza y accede a los servicios de salud, incorporando herramientas digitales a lo largo del ciclo del cuidado definido en las etapas de promoción, prevención, diagnóstico, tratamiento, seguimiento y educación.¹¹

A pesar de las conocidas limitaciones en el acceso equitativo a las tecnologías de salud en diferentes regiones, condicionadas por diferentes factores que afectan tanto a su implementación como disponibilidad,^{12,13} el fenómeno de salud digital se ha acelerado en los últimos años, especialmente tras la pandemia de la COVID-19, que actuó como catalizador para la adopción masiva de soluciones digitales en contextos donde el contacto presencial se volvió limitado o incluso inviable.¹⁴

1.2.1. Tecnologías digitales aplicadas a la salud

Comprender los principales conceptos que conforman el ecosistema de la salud digital es fundamental para interpretar, discutir y analizar las perspectivas relacionadas con estas herramientas, tanto en contextos generales como en aspectos concretos del cuidado de la salud visual (Figura 1.2).




Figura 1.2. Representación esquemática de los principales componentes que conforman el ecosistema de la salud digital. Adaptado y reilustrado de HealthDataForum.¹⁵

- **eHealth (salud electrónica):** Es un término amplio que abarca todas las aplicaciones de las TICs en el ámbito de la salud, incluyendo sistemas de registros clínicos electrónicos, plataformas de gestión de pacientes, portales digitales para profesionales y sistemas de apoyo a la decisión clínica.^{11,16} En los cuidados oculares, soluciones eHealth facilitan la integración de antecedentes clínicos con resultados de pruebas e imágenes, lo que contribuye a mejorar la continuidad del cuidado y la coordinación entre diferentes niveles de atención.¹⁷

- **mHealth (salud móvil):** Se refiere al uso de dispositivos móviles, como smartphones y tabletas, para acciones relacionadas con la salud, que incluye aplicaciones para el autocuidado, monitorización de enfermedades crónicas, recordatorios de medicación y recopilación de datos en tiempo real.¹⁸ Su portabilidad y bajo costo la convierten en una herramienta poderosa para poblaciones jóvenes o en contextos de acceso limitado.¹⁹ En salud visual, existen aplicaciones que permiten a los pacientes controlar el tiempo de uso de lentes de contacto, recibir alertas para la instilación de colirios o incluso realizar autoevaluaciones básicas de agudeza visual o sensibilidad al contraste.²⁰
- **Telemedicina / Telesalud:** Comprende la prestación de servicios a distancia mediante el uso de TICs, en general a través de plataformas dedicadas a este fin. Abarca consultas virtuales, interpretación remota de exámenes, emisión de informes y educación sanitaria.^{21,22} En optometría y oftalmología, se ha utilizado para realizar triajes visuales, seguimientos postoperatorios, orientaciones sobre síntomas oculares y derivaciones basadas en protocolos estandarizados.^{22,23} La telesalud ha demostrado ser efectiva para ampliar el acceso a servicios de cuidado de la salud visual en zonas rurales, reducir listas de espera en sistemas públicos, y también para contribuir a la educación continua del paciente mediante plataformas audiovisuales o sincrónicas.²⁴
- **Internet de las Cosas (IoT):** Hace referencia a una red de dispositivos interconectados capaces de recolectar, enviar y

procesar datos sin intervención humana directa, permitiendo la monitorización remota y continua de diferentes variables fisiológicas.²⁵ En oftalmología, por ejemplo, se han desarrollado biosensores implantables o portátiles para medir la presión intraocular en tiempo real, dispositivos para detectar la adherencia al tratamiento, o lentes de contacto inteligentes con sensores integrados para analizar el entorno de la superficie ocular.^{26,27}

- **Wearables (dispositivos vestibles):** Son dispositivos tecnológicos que se llevan puestos en el cuerpo y permiten registrar diferentes parámetros biológicos o conductuales. Comprenden gafas inteligentes, bandas oculares, relojes con sensores de actividad ocular, entre otros.²⁵ Algunos prototipos desarrollados para salud visual han demostrado utilidad en el análisis del parpadeo, el seguimiento de la posición ocular en pacientes con estrabismo o el control de exposición luminosa en usuarios con fotofobia.²⁸ También se ha analizado su uso en procesos de rehabilitación visual y como apoyo a personas con baja visión mediante asistentes auditivos conectados.^{29,30}

El avance de estas tecnologías ha abierto nuevas posibilidades para ampliar el acceso, agilizar procesos y mejorar la coordinación entre niveles de atención, con la intención de fomentar una atención más centrada en el usuario.¹¹ Aplicaciones móviles, plataformas de telesalud y sistemas interconectados permiten no solo acercar servicios a contextos antes desatendidos, sino también promover el autocuidado, facilitar la educación sanitaria y apoyar decisiones clínicas en tiempo real.¹⁴

Sin embargo, su uso también conlleva desafíos, entre los que pueden destacar las desigualdades en el acceso a dispositivos y conectividad, la baja alfabetización digital en ciertos grupos poblacionales o la variabilidad en la calidad de las herramientas disponibles, que son obstáculos comunes en distintos contextos.^{12,13} A estos se suman las preocupaciones éticas relacionadas con la automatización del cuidado, la transparencia de los algoritmos y el uso de datos clínicos, cuya gestión segura y responsable se vuelve cada vez más relevante y necesaria.^{31,32}

1.2.2. Sistemas de apoyo en la práctica clínica

Además de las clasificaciones generales anteriormente descritas, de conceptos como eHealth o telesalud, existen diversos sistemas digitales (softwares) diseñados para apoyar directamente la actividad en salud. Estos sistemas no conforman una categoría tecnológica cerrada, sino que pueden ser clasificados por su propósito funcional, ya sea para facilitar, organizar o enriquecer el proceso de atención sanitaria. Entre los tipos más comunes se encuentran:

- **Sistemas de gestión clínica** (como historias clínicas electrónicas, agendas inteligentes o plataformas de interoperabilidad);^{16,33}
- **Sistemas de triaje asistido y monitorización remota**, que orientan al usuario en función de síntomas iniciales o permiten el seguimiento domiciliario mediante sensores o aplicaciones móviles;^{34,35}
- **Asistentes virtuales de salud**, capaces de ofrecer información o guiar al paciente mediante interfaces

conversacionales,^{36,37} los cuales se abordaren con más detalle en el apartado 1.4 de este capítulo;

- **Sistemas de apoyo a la toma de decisiones clínicas (CDSS)**, que se explican en detalle a continuación.

Los CDSS son herramientas digitales diseñadas para asistir a los profesionales de la salud en la toma de decisiones, ofreciendo sugerencias, alertas, análisis o recomendaciones diagnósticas, terapéuticas o de manejo. Su funcionamiento puede basarse en reglas clínicas preestablecidas, bases de datos estructuradas, protocolos médicos o algoritmos de IA,³⁸ pudiendo actuar en distintas fases del proceso clínico, desde alertar sobre posibles contraindicaciones o interacciones medicamentosas, hasta sugerir la necesidad de derivación o realizar un análisis automatizado de datos clínicos complejos.³⁹

En contextos integrados, los CDSS pueden formar parte de historias clínicas electrónicas o plataformas de telesalud, aportando información adicional al profesional en tiempo real.^{33,39} Como ejemplos en el ámbito de la salud visual, pueden mencionarse aplicaciones que analizan imágenes de fondo de ojo para detectar signos tempranos de retinopatía diabética, priorizando casos que requieren evaluación urgente.^{17,40,41} Por lo tanto, la integración de estos sistemas en la práctica clínica puede reducir errores, mejorar la eficiencia diagnóstica y estandarizar protocolos, especialmente en contextos donde los recursos humanos son limitados o la variabilidad en la experiencia clínica es significativa.^{38,39}



1.3. Datos clínicos como base para la innovación

La expansión de las tecnologías digitales en salud ha estado directamente vinculada al crecimiento exponencial de los datos disponibles, es decir, a la capacidad de recolectar, almacenar y procesar grandes volúmenes de información, incluidos los datos clínicos, que han impulsado la investigación sanitaria, caracterizada por la posibilidad de identificar patrones, predecir comportamientos y apoyar decisiones, incluso en tiempo real.⁴² Este fenómeno, comúnmente denominado *big data*, puede aplicarse de forma concreta al ámbito de la salud, aunque posee un alcance mucho más amplio que este ámbito, ya que no se limita únicamente a la cantidad de datos, sino que también implica aspectos como su variedad, velocidad de generación, veracidad y valor potencial, conocidos como las “5V” del *big data*.⁴³

La combinación de estos elementos tiene el potencial de convertir estos datos en un recurso estratégico (Figura 1.3), tanto para la gestión de servicios como para el desarrollo de soluciones innovadoras, con diferentes tecnologías, pero especialmente aquellas basadas en IA.⁴⁴ No obstante, el aprovechamiento efectivo de este recurso depende de estructuras específicas para su recolección, organización y acceso. Con este propósito, los Registros Electrónicos de Salud (RES), también conocidos como *Electronic Health Records* (EHR) en la literatura internacional, así como las plataformas de repositorios de datos,

cumplen un papel fundamental como punto de partida para cualquier innovación sustentada en datos clínicos.⁴²

Los RES representan la principal fuente estructurada de información clínica en los sistemas sanitarios modernos, a partir de los cuales se ha permitido no solo digitalizar la historia sanitaria del paciente, sino también integrar múltiples fuentes de información, tales como laboratorios, imágenes, consultas, entre otras, en un único sistema digital accesible y reutilizable.^{42,45} A partir de estos registros electrónicos, se han desarrollado repositorios clínicos más amplios y especializados, que pueden ser clasificados según su propósito principal, principalmente como:

- *Clinical Data Warehouses (CDW)*: almacenes de datos clínicos orientados a la gestión asistencial y operativa;
- *Research Data Warehouses (RDW)*: bases enfocadas en apoyar la investigación científica mediante la extracción estructurada de datos;
- *Integrated Data Repositories (IDR)*: plataformas integradas que reúnen datos clínicos, administrativos y de múltiples fuentes para análisis transversales complejos.

Estas infraestructuras se encargan de gestionar y administrar grandes volúmenes de información en entornos seguros y de acceso controlado,^{46,47} lo que posibilita la realización de análisis retrospectivos de datos poblacionales, la creación de cohortes clínicas, la monitorización de la calidad asistencial, el diseño de estrategias de intervención personalizadas,⁴⁸ así como ofrecer una base estructurada

de datos que puede ser utilizada en el desarrollo y entrenamiento de modelos de IA.⁴⁵




Figura 1.3. Esquema general de integración de datos clínicos en sistemas digitales, con almacenamiento en la nube y acceso por distintos actores. Adaptado y reilustrado de Agrawal and Prabakaran.⁴⁹

1.3.1. Potencial, limitaciones y desafíos actuales

Pese a su importancia para el fomento de investigaciones y el desarrollo de tecnologías en salud digital, el uso de datos clínicos se enfrenta a obstáculos significativos. Uno de los más recurrentes es la falta de estandarización en los formatos y en la codificación de la información, lo que dificulta la interoperabilidad entre sistemas y el uso secundario de los datos con fines de investigación. Además, muchos conjuntos de datos carecen de metadatos adecuados, documentación

clara o criterios mínimos de calidad, lo que compromete su reutilización de forma segura y válida.^{42,45} A estas cuestiones de orden técnico se suman preocupaciones igualmente relevantes y delicadas, relacionadas con la privacidad, la protección de datos personales y el consentimiento informado para usos secundarios.^{22,32} Las dimensiones éticas, tanto en lo que respecta a la obtención como al uso de los datos, se han vuelto cada vez más un aspecto fundamental, especialmente en contextos donde el empleo de algoritmos y modelos automatizados puede tener un impacto directo en las decisiones asistenciales.^{50,51}

A pesar de estos desafíos, el uso estratégico de datos clínicos bien estructurados presenta un potencial significativo para transformar los sistemas de salud. Cuando los datos están disponibles, organizados y accesibles bajo marcos éticos adecuados, pueden convertirse en una herramienta poderosa para el desarrollo de sistemas digitales de apoyo a la salud, en sus más variados niveles y funciones: desde la optimización de procesos asistenciales y la mejora de la precisión diagnóstica, hasta el apoyo a las decisiones clínicas basadas en evidencia y el diseño de intervenciones más personalizadas y eficientes.^{42,45} Como ejemplo, el análisis de grandes bases de datos ha permitido identificar la distribución poblacional de errores refractivos y establecer patrones asociados a la miopía en distintos grupos poblacionales.^{52,53} También se han utilizado datos clínicos para estudiar la progresión de enfermedades como el glaucoma mediante la comparación longitudinal de mediciones de presión intraocular y del campo visual,^{54,55} o para analizar tendencias en prescripciones ópticas y su relación con factores ambientales o conductuales, lo que ha contribuido a estrategias de prevención y planificación de servicios visuales.^{42,45}

Además, la posibilidad de integrar información proveniente de distintas fuentes - como registros electrónicos, sensores, dispositivos móviles o datos poblacionales - permite generar una visión más integral del paciente y de la población, lo que abre oportunidades para modelos de atención más predictivos y centrados en las personas.^{11,16} No obstante, es esencial considerar que la segmentación poblacional o el uso inadecuado de características sociodemográficas puede acarrear riesgos éticos, comprometiendo la equidad en la atención.^{22,56,57} En definitiva, la disponibilidad y el acceso a datos de calidad constituyen no solo un recurso valioso, sino una condición fundamental para impulsar innovaciones sostenibles en salud digital, especialmente aquellas que incorporan IA y aprendizaje automático como herramientas de apoyo.^{58,59}



1.4. Asistentes virtuales en el ámbito de la salud

Los asistentes virtuales, también conocidos como agentes conversacionales o *chatbots*, representan una de las interfaces más visibles entre los usuarios y los sistemas de IA. Aunque inicialmente vinculados a servicios comerciales, su presencia en el ámbito sanitario ha crecido en los últimos años, tanto en funciones administrativas como clínicas básicas,⁶⁰ en gran parte impulsada por el avance de técnicas de IA como el procesamiento de lenguaje natural, el aprendizaje profundo y el desarrollo de modelos conversacionales, que han ampliado su capacidad de respuesta, adaptación y personalización.⁶¹ La expansión de interfaces accesibles, como aplicaciones móviles, plataformas web o incluso asistentes por voz, ha facilitado aún más su integración en los sistemas de salud, ofreciendo funcionalidades diversas, que van desde la orientación personalizada, educación en salud, seguimiento automatizado, hasta el apoyo en decisiones clínicas rutinarias.^{36,60}

Un asistente virtual puede definirse como una herramienta digital programada para interactuar con el usuario mediante lenguaje natural, simulando una conversación orientada a una función específica. Estos sistemas pueden integrarse en dispositivos como teléfonos móviles, terminales hospitalarios o entornos web, presentarse en formatos textuales, por voz o híbridos y su complejidad varía desde flujos conversacionales rígidos, basados en reglas simples, hasta sistemas adaptativos que emplean modelos de lenguaje de gran escala (LLM),

como los actuales GPT, capaces de generar respuestas dinámicas y contextualmente relevantes.⁶² Entre los ejemplos más conocidos de asistentes virtuales generales se encuentran Alexa, Siri y Google Assistant (Figura 1.4 – parte superior), que, aunque no están diseñados específicamente para el ámbito sanitario, han popularizado el concepto de interfaz conversacional y abierto el camino para desarrollos más especializados.³⁶




Figura 1.4. Parte superior (línea discontinua): asistentes virtuales generales más populares y sus fechas de lanzamiento. Parte inferior (línea punteada): principales aplicaciones de asistentes virtuales en el ámbito sanitario. Adaptado y reilustrado de Aftab⁶³ y KeyReply.⁶⁴

A diferencia de los asistentes virtuales generalistas, los aplicados al ámbito de la salud están concebidos para cumplir funciones específicas orientadas al cuidado (Figura 1.4 – parte inferior), cuyas funcionalidades dependen tanto del enfoque del desarrollo como del grado de integración con los sistemas sanitarios existentes.¹⁷ Estas herramientas han sido empleadas en una amplia variedad de contextos, siendo el triaje uno de los usos más comunes, en el cual el sistema recopila información preliminar sobre síntomas del paciente y orienta sobre el nivel de atención requerido o la especialidad a consultar, mediante preguntas estructuradas.^{37,60,65} También se destacan en el acompañamiento de pacientes con enfermedades crónicas, a través de funciones como la monitorización diaria de síntomas, recordatorios de medicación o sugerencias personalizadas de autocuidado, etc., que contribuyen a mejorar la adherencia terapéutica y reducir visitas innecesarias a los profesionales.^{17,35} Igualmente, han demostrado su utilidad en el ámbito de la salud mental, proporcionando orientación emocional básica y promoviendo técnicas de autorregulación, especialmente en poblaciones jóvenes.^{66,67} También se suman las aplicaciones en procesos de educación sanitaria, con el empleo de materiales interactivos que explican condiciones de salud general, preparan al paciente para exámenes o intervenciones, y refuerzan mensajes relacionados con hábitos saludables.³⁶ Por otra parte, algunos modelos más avanzados han sido integrados como soporte a la toma de decisiones clínicas, actuando como primer filtro o asistente digital en la interpretación de datos clínicos, aunque en términos generales siguen siendo considerados herramientas complementarias al juicio profesional.^{31,60}

A pesar del crecimiento sostenido en las propuestas de asistentes virtuales en diversas especialidades de salud, como la medicina general, la salud mental o la endocrinología,^{37,60,61,65} su uso específico en el ámbito de la salud visual sigue siendo muy limitado y poco explorado. Aunque los ejemplos concretos aún son escasos, ya se han reportado iniciativas que apuntan al uso de *chatbots* en educación en salud ocular, orientación básica y apoyo al triaje de síntomas visuales, lo que refuerza su potencial como herramientas de apoyo temprano e intermediación digital responsable.^{17,36,37,67} De esta manera, los asistentes virtuales emergen no solo como una alternativa tecnológica viable, sino como un componente estratégico para ampliar el acceso al cuidado de la salud visual, reducir barreras informativas y fortalecer el vínculo entre los usuarios y los servicios de atención visual.



1.5. IA y sus aplicaciones en salud

1.5.1. Principios básicos y fundamentos de la IA

En este apartado se presentan los fundamentos esenciales de la IA, con el objetivo de ofrecer una comprensión clara y aplicada para profesionales de la salud que no necesariamente cuentan con formación técnica en computación o conocimiento profundo relacionado con estas tecnologías. De este modo, específicamente en esta sección, la estructura ha sido diseñada con un enfoque basado en preguntas orientadoras, que busca facilitar la comprensión progresiva de los principales conceptos, tipos de enfoque, arquitecturas y algoritmos, adaptando las ejemplificaciones al desarrollo de soluciones en salud, especialmente en el ámbito visual y ocular, con el fin de construir una base sólida sobre la temática que sustenta los principios de la tesis.

Nota al lector: Aunque los contenidos de esta sección se han elaborado con un enfoque accesible para profesionales de la salud sin formación en área tecnológica, se reconoce que algunos lectores pueden ya contar con conocimientos previos sobre los fundamentos de la IA. En tal caso, y si se considera apropiado, se puede avanzar directamente al ítem 1.5.2, sin perjuicio de la comprensión general del texto.

A. ¿Qué es la IA y cómo funciona?

La IA se ha consolidado como una de las áreas más dinámicas y transformadoras del desarrollo tecnológico en las últimas décadas. Aunque el término puede implicar distintas interpretaciones, en términos generales se entiende como un campo de la informática dedicado al diseño de sistemas capaces de realizar tareas que antes requerían inteligencia humana, como el reconocimiento de patrones, la toma de decisiones, el aprendizaje y la adaptación, sin depender de una programación explícita y predefinida para cada situación.⁶⁸ Su origen se remonta a la década de 1950, en el contexto de los primeros intentos de simular el razonamiento humano en máquinas. Sin embargo, fue el avance en la capacidad de memoria y velocidad de procesamiento lo que permitió el desarrollo del aprendizaje automático (*machine learning*, *ML*) y, posteriormente, de sus vertientes más complejas como el aprendizaje profundo (*deep learning*, *DL*), que dieron un nuevo impulso a las aplicaciones modernas de la IA.^{11,59,69}

Desde el punto de vista funcional, el comportamiento general de un sistema de IA puede entenderse como una secuencia lógica de tres etapas: entrada, procesamiento y salida. Primero, el sistema recibe una entrada - como una imagen o un conjunto de datos - que se traduce en una representación matemática interna. A continuación, un modelo de IA (previamente entrenado por un algoritmo específico) procesa esa información mediante cálculos que permiten identificar patrones o tomar decisiones. Finalmente, se genera una salida, cuya forma dependerá del objetivo del sistema, como por ejemplo una clasificación, una predicción o una respuesta automatizada.^{59,69}

B. ¿Qué son y cómo se relacionan un algoritmo y un modelo en IA?

Un algoritmo puede entenderse como un conjunto de reglas o instrucciones lógicas que definen cómo deben procesarse los datos para resolver una tarea específica (Figura 1.5).

- Algoritmos de IA: En el contexto de la IA, los algoritmos pueden entenderse como un conjunto de mecanismos - en general, combinaciones o variaciones matemáticas - que permiten ajustar sus propias reglas a partir de ejemplos. A diferencia de los algoritmos tradicionales, en los que todas las decisiones están explícitamente programadas por el desarrollador, los algoritmos de IA tienen la capacidad de aprender y optimizar su funcionamiento con base en datos. Se los puede comparar con un protocolo clínico general que establece los pasos a seguir para transformar una entrada - como un examen de imagen o una serie de síntomas - en una salida útil, como una clasificación o una predicción, aunque aún no haya sido personalizado ni adaptado a un caso específico.^{11,13,69}

- Modelo de IA: A partir de estos algoritmos dedicados, se entrena un modelo, que es el resultado de aplicar dicho algoritmo sobre un conjunto específico de datos y ajustarlo para resolver un problema concreto. Mientras el algoritmo define la lógica general, el modelo de IA representa su especialización práctica, ya que ha sido entrenado y está listo para operar sobre nuevos casos. Por ejemplo, un algoritmo de clasificación puede ser entrenado con imágenes de retina previamente etiquetadas como “normal” o “con retinopatía”;

tras ese proceso, el sistema se convierte en un modelo funcional, capaz de analizar nuevas imágenes y sugerir una categoría.^{69,70}

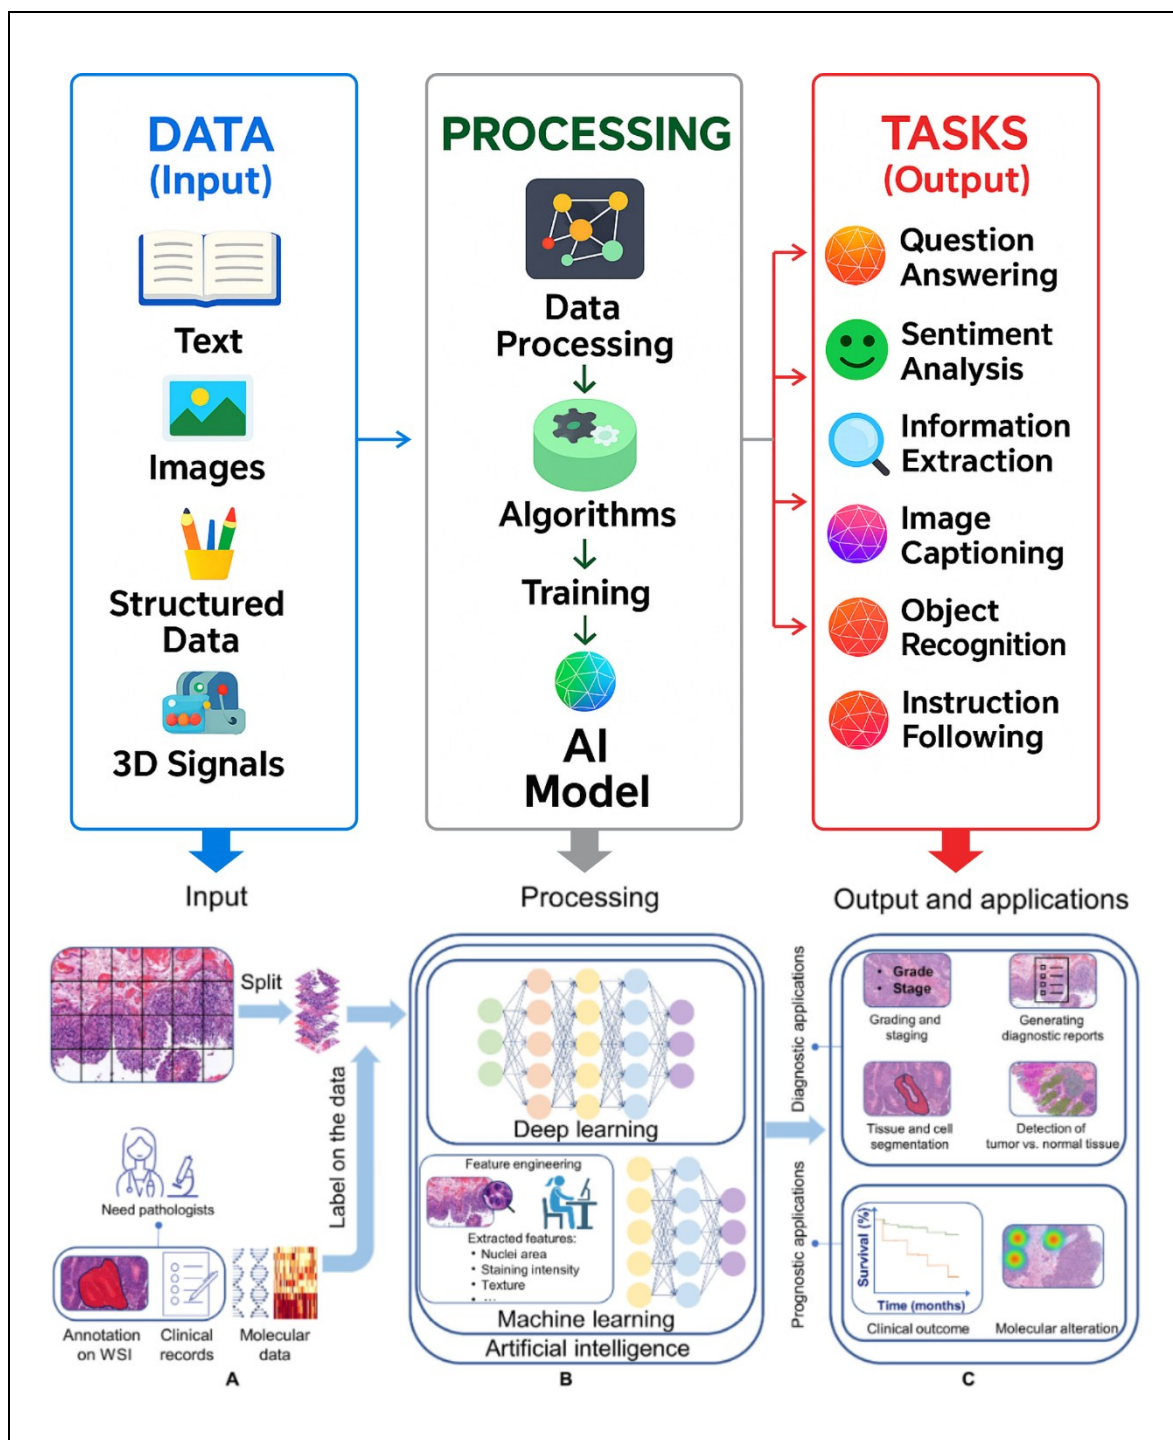


Figura 1.5. Esquema general del flujo de datos en IA, desde la entrada y el procesamiento hasta las aplicaciones clínicas. Parte superior adaptado y reelustrado de Zhang et al.⁷¹ y parte inferior reproducida de Zou et al. (CC BY 4.0).⁷²

Es importante destacar que las decisiones producidas por un modelo de IA no están predefinidas en el código, sino que emergen de un proceso de aprendizaje basado en datos. Justamente esta diferencia respecto de las programaciones tradicionales, donde cada decisión sigue un flujo explícitamente codificado, es lo que sustenta el uso del término “inteligencia artificial”, aunque en última instancia continúe siendo un conjunto de procesos lógicos estructurados a partir de ejemplos proporcionados por el conocimiento humano.^{11,73}

C. ¿Cómo se implementa un modelo de IA en la práctica?

La implementación de un modelo de IA, en términos prácticos, comienza con la recopilación de un conjunto de datos que puede incluir texto, imágenes, señales o registros estructurados. La calidad de estos datos influye directamente en la capacidad del modelo para aprender de forma precisa y confiable. Para que puedan ser utilizados de manera efectiva, es necesario que se encuentren en condiciones adecuadas para el procesamiento, lo que requiere una etapa previa de preprocesamiento, que incluye acciones como limpieza, adecuación de variables y manejo de valores perdidos o ausentes, entre otras.^{42,45} Todo este proceso suele llevarse a cabo mediante entornos de programación como Python, utilizando bibliotecas específicas que permiten preparar los datos, aplicar los algoritmos y entrenar los modelos.⁷⁴

Una vez preparado el conjunto de datos, se selecciona un algoritmo de IA compatible con el tipo de problema que se desea resolver y se procede al entrenamiento del modelo, lo que requiere dividir aleatoriamente el conjunto total en al menos dos partes principales que cumplen funciones distintas dentro del proceso de aprendizaje.^{75,76}

- Conjunto de entrenamiento: utilizado para enseñar al modelo a generar respuestas a partir de los datos. Suele representar entre el 60 % y el 80 % del total de los datos disponibles.
- Conjunto de prueba: correspondiente a la porción restante, reservada para evaluar el rendimiento del modelo con datos que no fueron utilizados durante el entrenamiento. Esta separación es esencial para evitar una evaluación sesgada y verificar si el modelo generaliza correctamente más allá de los datos con los que fue entrenado.

Según la naturaleza del problema y la disponibilidad de resultados, conocidos como etiquetas, por ejemplo un diagnóstico o una clasificación previa ya definida para cada caso, los modelos de IA pueden entrenarse según distintas modalidades de aprendizaje. Estas clasificaciones del entrenamiento pueden combinarse o adaptarse según la complejidad de la tarea, lo que proporciona mayor flexibilidad para su aplicación en diferentes contextos.

- Aprendizaje supervisado: requiere datos con resultados conocidos, ya que el objetivo es aprender a asociar entradas con salidas. Por ejemplo, un conjunto de imágenes de retina clasificadas como “sanas” o “patológicas” permite entrenar el modelo para que clasifique nuevas imágenes con base a ese aprendizaje.²³
- Aprendizaje no supervisado: se aplica cuando no se dispone de una base de datos con etiquetas específicas, y el modelo intenta descubrir estructuras, agrupamientos o relaciones

internas en los datos. Por ejemplo, al analizar respuestas de cuestionarios de pacientes sin diagnóstico previo, el modelo puede detectar grupos con perfiles similares sin que estos hayan sido definidos de antemano.⁴²

- Aprendizaje por refuerzo: el modelo interactúa con un entorno y ajusta su estrategia para maximizar un resultado deseado. Por ejemplo, un modelo generativo de lenguaje, como un *chatbot*, puede aprender a mejorar progresivamente sus respuestas a partir de la retroalimentación humana, optimizando así la calidad de la interacción con los usuarios.^{70,77}

D. ¿Qué tipos de salidas pueden generar los modelos de IA?

Los modelos de IA pueden generar distintos tipos de salidas, que varían según el objetivo de la tarea y, de forma general, se pueden agrupar en las siguientes categorías principales:⁷⁵

- Clasificación: cuando la salida es una o más clases definidas. Puede tratarse de una clasificación binaria, donde solo hay dos categorías posibles, como identificar si una imagen corresponde a un ojo sano o con retinopatía diabética, o de una clasificación multiclase, donde existen más de dos posibilidades, como en un modelo que distingue entre diferentes tipos de patologías oculares (por ejemplo: glaucoma, degeneración macular, retinopatía diabética o sin patología).²³
- Regresión: cuando el resultado es un valor numérico. Esto es útil, por ejemplo, para estimar el grosor de una capa del

nervio óptico a partir de imágenes. Además, la regresión puede ser simple, cuando predice una sola variable numérica, como la refracción estimada a partir de imágenes⁷⁸ o múltiple, cuando genera varias salidas numéricas simultáneamente, como la presión intraocular, el grosor corneal y la refracción subjetiva en un mismo modelo.⁷⁹

Es importante destacar que las tareas anteriores, de tipo más tradicional (Figura 1.6), suelen estar asociadas a una categoría de IA conocida como aprendizaje automático (*machine learning*). No obstante, existen otros tipos de salida más especializados, especialmente relevantes en contextos complejos, que generalmente requieren arquitecturas más avanzadas, propias del DL.⁵⁹

- Segmentación: consiste en dividir una imagen en regiones con significado clínico, como, por ejemplo, delimitar el área con edema macular en una imagen OCT.^{69,80}
- Detección de objetos: para localizar estructuras específicas dentro de una imagen, como microaneurismas o lesiones focales.^{81,82}
- Generación de texto o imagen: típica de los modelos generativos de lenguaje de gran escala (LLMs, por sus siglas en inglés), capaces de producir contenido nuevo en respuesta a una entrada, y que se han vuelto ampliamente conocidos a través de herramientas actuales como los modelos ChatGPT.^{62,70}

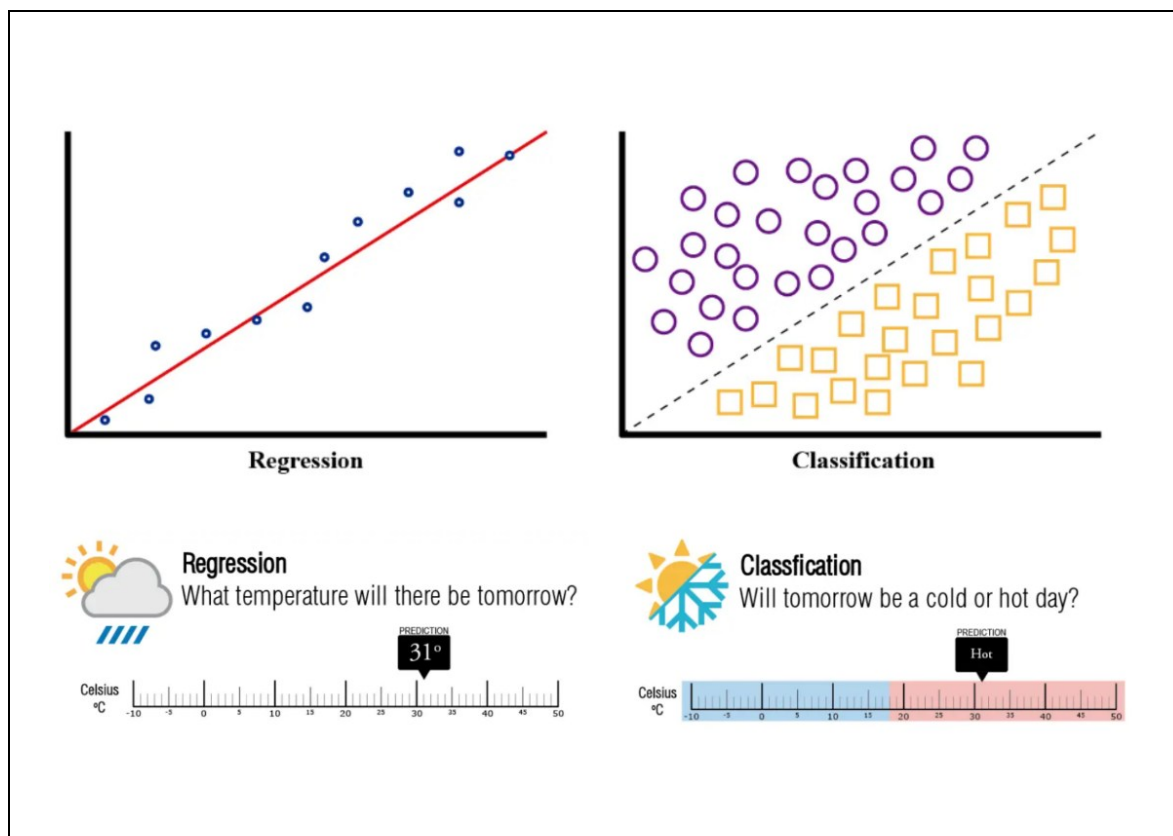


Figura 1.6. Representación comparativa entre regresión y clasificación en aprendizaje automático. Imagen adaptada de Panama Hitek.⁸³

E. ¿Cómo se evalúa el rendimiento de un modelo de IA?

La evaluación del rendimiento de un modelo de IA se basa en métricas específicas que permiten juzgar su precisión, utilidad y confiabilidad, cuya elección depende del tipo de tarea, del tipo de salida generada (clasificación o regresión) y del contexto en el que se pretende aplicar el modelo. Las métricas utilizadas en problemas de clasificación se destacan por incluir la exactitud, sensibilidad, especificidad, precisión, F1-score, AUC-ROC y la matriz de confusión (Figura 1.7); mientras que otras son propias de tareas de regresión, como el error absoluto medio (MAE, por sus siglas en inglés), el error cuadrático medio (RMSE, por sus siglas en inglés) y el coeficiente de determinación

(R^2). Los detalles de cada una de estas métricas se presentan en la Tabla 1.1.^{43,69,84}




Figura 1.7. Matriz de confusión, a la izquierda, y curva ROC, a la derecha, para la evaluación de modelos de IA. Parte superior (línea discontinua): ilustraciones conceptuales sobre el funcionamiento e interpretación. Parte inferior (línea punteada): ejemplo práctico de las métricas. Imágenes adaptadas y reilustradas de DataCamp,⁷⁶ Deepchecks⁷⁵ y El Khal.⁸⁵

Tabla 1.1 Métricas comunes para la evaluación de modelos de IA, compiladas a partir de estudios publicados.^{43,69,75,76,84} Parte superior: evaluación de clasificación. Parte inferior: evaluación de regresión.

Métrica	Descripción	Rango / Interpretación	Aplicación típica
<i>Salidas de clasificación (clases)</i>			
Exactitud (accuracy)	Proporción de aciertos totales sobre el total de predicciones.	0 a 1 - mayor = mejor desempeño general.	Clasificación binaria o multiclase con clases balanceadas.
Sensibilidad (recall)	Capacidad del modelo para identificar correctamente los casos positivos.	0 a 1 - mayor = menos falsos negativos.	Triaje clínico - cuando es importante no omitir positivos.
Especificidad	Capacidad del modelo para identificar correctamente los casos negativos.	0 a 1 - mayor = menos falsos positivos.	Diagnóstico confirmatorio - para reducir falsos positivos.
Precisión (precision)	Proporción de verdaderos positivos entre todos los casos clasificados como positivos.	0 a 1 - mayor = mayor confianza en la predicción positiva.	Contextos con impacto clínico de falsos positivos.
F1-score	Media combinada entre precisión y sensibilidad.	> 0.8 suele indicar buen equilibrio entre precisión y sensibilidad.	Clases desbalanceadas o eventos poco frecuentes.
AUC-ROC	Área bajo la curva ROC que compara sensibilidad vs. 1 – especificidad.	0 a 1 - mayor = mejor discriminación entre clases.	Evaluación global de discriminación entre clases.
Matriz de confusión	Tabla visual que compara predicciones con resultados reales por categoría.	Visual - no tiene escala numérica directa.	Clasificación - análisis de patrones de error.
<i>Salidas de regresión (numérica)</i>			
Error absoluto medio (MAE)	Promedio del valor absoluto de los errores entre predicción y valor real.	0 a ∞ - menor = errores promedio más bajos.	Tareas de estimación clínica numérica.
Error cuadrático medio (RMSE)	Promedio del cuadrado de los errores entre predicción y valor real.	0 a ∞ - menor = errores más penalizados.	Penaliza errores grandes más fuertemente.
Coeficiente de determinación (R^2)	Proporción de la variabilidad de la salida que es explicada por el modelo.	0 a 1 - mayor = mayor capacidad explicativa del modelo.	Mide el ajuste del modelo a los datos reales.

Aunque todas las métricas descritas pueden aportar información relevante para interpretar el desempeño del modelo, algunas de ellas se utilizan con mayor frecuencia, como la exactitud y la sensibilidad en tareas de clasificación, mientras que en tareas de regresión destaca el uso del RMSE y R^2 . Aunque es habitual analizar un modelo con varias métricas simultáneamente, la selección adecuada de la métrica principal puede ser crucial para una situación concreta; en este sentido, en una herramienta de cribado clínico, por ejemplo, puede ser preferible maximizar la sensibilidad, incluso si eso implica aceptar un mayor número de falsos positivos, ya que lo más importante es no clasificar como sano un caso afectado por el problema a estudiar.^{43,84} Además de las métricas, existen otros conceptos que complementan la evaluación y validación de modelos de IA:

- Sobreajuste (*overfitting*): fenómeno en el cual el modelo se ajusta de forma excesiva a los datos de entrenamiento, logrando métricas elevadas en ese conjunto, pero fallando al aplicarse a nuevos casos reales. Este comportamiento genera una falsa percepción de rendimiento y suele deberse a una baja diversidad o representatividad en los datos utilizados, lo que limita la capacidad del modelo para generalizar su aprendizaje a otros escenarios. En sentido contrario, el subajuste (*underfitting*) ocurre cuando el modelo ni siquiera logra identificar patrones relevantes durante el entrenamiento, resultando en un bajo rendimiento general.^{59,69}
- Desbalanceo entre clases: ocurre cuando una categoría está significativamente sobrerrepresentada en relación con otra, como suele pasar en contextos clínicos en los que los

“casos sanos” son mucho más frecuentes que los “casos enfermos”. Este desequilibrio puede sesgar el aprendizaje del modelo, dificultando su capacidad para detectar correctamente la clase minoritaria. Para mitigar este efecto, existen estrategias como la regularización o el uso de datos sintéticos, que ayudan a equilibrar la distribución de clases.^{57,81}

- Validación cruzada (cross-validation): se trata de una estrategia ampliamente utilizada para obtener una evaluación más robusta del modelo, que consiste en dividir el conjunto de datos en varios subconjuntos (por ejemplo, cinco o diez partes), usando cada uno de ellos como conjunto de prueba en diferentes rondas, mientras se entrena con los subconjuntos restantes. Este procedimiento permite estimar de forma más confiable y generalizable el rendimiento real del modelo.^{69,75}

F. ¿Cómo se clasifican los enfoques de IA?

El campo de la IA abarca diversas subcategorías (Figura 1.8) que pueden clasificarse con distintos enfoques. Una forma común de clasificación considera su arquitectura y método de aprendizaje.

- Aprendizaje automático (machine learning, ML) se refiere a los sistemas capaces de aprender patrones a partir de datos, usualmente estructurados en formato tabular, donde los algoritmos ajustan sus parámetros internos con base en ejemplos previos para realizar predicciones, ya sea de clasificación o regresión. Por ejemplo, un modelo de aprendizaje automático puede ser entrenado para estimar la

presión intraocular a partir de variables clínicas estructuradas.^{13,29}

▪ Aprendizaje profundo (deep learning, DL) constituye una evolución del aprendizaje automático que emplea redes neuronales artificiales de múltiples capas (*Artificial Neural Networks, ANN*), estructuras inspiradas en el funcionamiento del cerebro humano y compuestas por nodos (neuronas artificiales). Estas redes son capaces de transformar progresivamente la información desde formas más simples hasta representaciones complejas y abstractas. Una forma sencilla de entender su funcionamiento es imaginar una cadena de filtros conectados en la que cada capa realiza una transformación sobre los datos, como si cada filtro extrajera características cada vez más específicas, lo que permite que el sistema aprenda desde detalles básicos hasta patrones sofisticados. Este es uno de los campos más activos actualmente, con avances continuos y múltiples variantes. Entre las arquitecturas más conocidas se destacan las redes neuronales convolucionales (CNN), diseñadas para el procesamiento de imágenes y ampliamente utilizadas en el análisis de tomografías de coherencia óptica (OCT) o fondo de ojo; las redes neuronales recurrentes (RNN), adecuadas para tratar datos secuenciales, como los utilizados en el análisis de progresión de enfermedades; y los transformers, una arquitectura más reciente que revolucionó el procesamiento del lenguaje natural (PLN), dando origen a modelos como ChatGPT, capaces de generar y comprender el lenguaje con alta coherencia contextual.^{69,70,80,84,86}




Figura 1.8. Relación jerárquica entre IA, aprendizaje automático, redes neuronales y aprendizaje profundo. (CC BY 4.0)⁸⁷ CNN= redes neuronales convolucionales; RNN= redes neuronales recurrentes; GAN= redes generativas antagónicas; DBN= redes bayesianas profundas; MLP= perceptrón multicapa.

Además de las clasificaciones basadas en la arquitectura o en el tipo de aprendizaje, es común categorizar los enfoques de IA según su área de aplicación, lo que resulta particularmente útil en contextos clínicos para entender cómo estas tecnologías pueden integrarse en

distintas tareas. Esta perspectiva permite identificar con mayor claridad qué tipo de modelos son más adecuados para cada necesidad. Entre las principales áreas se incluyen:

- Visión computacional: se enfoca en el análisis automatizado de imágenes para extraer información significativa, reconocer patrones visuales o detectar anomalías. En el ámbito de la salud ocular, se emplea para identificar signos de patologías en imágenes de retina o de OCT, por ejemplo.^{69,84}
- Procesamiento de lenguaje natural (PLN): abarca métodos que permiten a las máquinas comprender, interpretar y generar lenguaje humano, tanto escrito como hablado. En salud, puede utilizarse para analizar historiales médicos escritos manualmente o para facilitar la comunicación mediante interfaces conversacionales inteligentes.^{62,70,88}
- Sistemas de recomendación: consisten en algoritmos diseñados para sugerir acciones o contenidos relevantes a partir del análisis de grandes volúmenes de datos y características del usuario. En contextos clínicos, pueden apoyar la toma de decisiones al priorizar riesgos o sugerir conductas según el perfil del paciente.^{24,89,90}
- Modelos generativos: permiten crear nuevos contenidos - como texto, imágenes o simulaciones - a partir de datos de entrada. En el área de la salud visual, se utilizan en asistentes virtuales que simulan escenarios clínicos o generan informes automatizados mediante grandes modelos de lenguaje (LLM).^{61,70,74,91}

G. ¿Qué algoritmos se utilizan y sus características?

Una vez introducidos los conceptos fundamentales, resulta útil presentar algunos de los algoritmos más comúnmente aplicados en el desarrollo de modelos de IA. Entre los algoritmos clásicos de ML se destacan la regresión logística, los árboles de decisión, *random forest*, las máquinas de vectores de soporte (SVM) y las redes neuronales simples (de una o dos capas ocultas), mientras que en el campo del DL se emplean arquitecturas más complejas basadas en ANN, donde entre las más conocidas se encuentran las CNN, RNN y los modelos generativos, como se detalla en la Tabla 1.2.^{21,69,84}

Tabla 1.2 Algoritmos comúnmente utilizados en el desarrollo de modelos de IA, compilada a partir de estudios publicados.^{24,43,69,74,91} ML = *Machine Learning*; DL = *Deep Learning*.

Algoritmo		Salida	Aplicación
Regresión logística (Logistic Regression)	ML	Clasificación y regresión	Análisis de variables clínicas estructuradas para predecir riesgo o diagnóstico
Árboles de decisión (Decision Trees)	ML	Clasificación y regresión	Segmentación de pacientes y rutas de decisión clínica
Random Forest	ML	Clasificación y regresión	Priorización de riesgo en enfermedades oculares a partir de múltiples variables
Máquinas de vectores de soporte (SVM)	ML	Clasificación	Identificación de patrones diagnósticos como tipos de queratocono
Redes neuronales simples	ML	Clasificación y regresión	Modelos básicos de predicción clínica usando pocas variables
Redes neuronales artificiales (ANN)	DL	Clasificación y regresión	Procesamiento de grandes volúmenes de datos clínicos con múltiples relaciones
Redes neuronales convolucionales (CNN)	DL	Imágenes	Análisis automatizado de OCT y fondo de ojo
Redes neuronales recurrentes (RNN)	DL	Secuencias / series temporales	Seguimiento longitudinal de enfermedades visuales
Modelos generativos	DL	Texto, imagen y simulación	Generación de informes clínicos o simulaciones educativas

1.5.2. Aplicaciones de la IA en salud

La incorporación de la IA en el ámbito sanitario representa una de las transformaciones tecnológicas más significativas de las últimas décadas,⁸¹ y aunque sus aplicaciones se extienden a numerosos sectores, es en el área de la salud donde su potencial de impacto se manifiesta con mayor claridad, en parte por la similitud entre la lógica que sustenta los sistemas de IA, basada en entradas, procesamiento y salidas, y el flujo operativo de los procesos clínicos, los cuales también se apoyan en múltiples fuentes de información, como historias clínicas, imágenes médicas y biomarcadores, para generar diagnósticos, establecer pronósticos o tomar decisiones que orienten la gestión clínica.^{59,73,92} Desde los primeros sistemas expertos desarrollados en la década de 1970, como el pionero “MYCIN”, diseñado para asistir en el diagnóstico de infecciones bacterianas,^{93,94} hasta los modernos algoritmos de aprendizaje profundo capaces de interpretar imágenes médicas con una precisión comparable a la de especialistas humanos,⁸¹ la evolución de la IA ha estado estrechamente ligada al campo de la salud, consolidando un camino de creciente sofisticación tecnológica y ampliación de sus posibilidades clínicas (Figura 1.9).

Con el avance de los métodos de aprendizaje automático y la creciente disponibilidad de datos sanitarios, provenientes de registros electrónicos, imágenes clínicas, sensores portátiles y bases de datos poblacionales, se ha vuelto viable desarrollar sistemas que no solo aumentan la eficiencia operativa de los servicios, sino que también personalizan el cuidado del paciente y ofrecen soporte a los profesionales en la toma de decisiones clínicas.^{21,81,95} Lejos de sustituir el juicio clínico, la IA se consolida como un complemento valioso, al

permitir el procesamiento rápido de grandes volúmenes de información compleja e identificar patrones que muchas veces escapan a la percepción humana,⁶⁹ lo que, al promover nuevas posibilidades para la prevención, el diagnóstico, el tratamiento y la monitorización de condiciones médicas, la posiciona como una tecnología clave dentro del ecosistema de la salud digital, ofreciendo respuestas innovadoras frente a desafíos cada vez más urgentes, ya sea por la escasez de profesionales cualificados o por la necesidad de una atención más precisa, eficiente y accesible,^{59,73} como lo demuestran las aplicaciones ya implementadas en distintas áreas clínicas:

- **Atención primaria y emergencias:** *Sistemas de triaje automatizado*, que priorizan a los pacientes según la gravedad de los síntomas o los resultados iniciales, con especial utilidad en contextos de alta demanda o en regiones con escasez de especialistas.⁸¹
- **Diagnóstico por imágenes:** *Algoritmos de análisis de imágenes médicas*, capaces de interpretar radiografías, tomografías, mamografías y fondos de ojo con una precisión comparable o superior a la de profesionales humanos en tareas específicas.^{59,96,97}
- **Medicina personalizada:** *Modelos predictivos basados en IA* que estiman la respuesta individual a determinados tratamientos, considerando datos genómicos, clínicos y ambientales, lo cual permite una terapéutica más precisa y adaptada a cada paciente.^{58,69}

- **Cardiología:** *Algoritmos entrenados con datos de electrocardiogramas y pruebas de laboratorio* que permiten predecir eventos adversos e identificar arritmias con alta sensibilidad.⁵⁹
- **Oncología:** *Modelos de predicción basados en biomarcadores e imágenes histopatológicas*, utilizados para la detección precoz de tumores y la estratificación de riesgos clínicos.⁷²
- **Dermatología:** *Sistemas de visión computacional* que clasifican lesiones cutáneas y asisten en la detección de cáncer de piel, especialmente en fases iniciales.⁶⁹
- **Psiquiatría y neurología:** *Herramientas basadas en patrones de lenguaje, escritura o comportamiento*, empleadas para generar hipótesis diagnósticas preliminares o monitorizar la evolución de diferentes trastornos neuropsiquiátricos.⁷⁴

Estos ejemplos ilustran cómo la IA ya se encuentra integrada en diferentes áreas del cuidado clínico, aportando valor tanto en tareas operativas como en procesos diagnósticos complejos, una vez que su aplicación no solo mejora la eficiencia, sino que también amplía las capacidades de observación y análisis en escenarios clínicos desafiantes, lo que permite resumir sus beneficios clave en distintos niveles asistenciales, tal como se presenta en la Tabla 1.3.




Figura 1.9. Esquema de capacidades clave de los sistemas de IA aplicada a salud. Adaptada y reilustrada de U.S. Government Accountability Office (GAO).⁹⁸

Tabla 1.3 Beneficios destacados de la IA en salud y ejemplos de aplicación, compilada a partir de estudios publicados.^{59,69,73,81,92}

Beneficio	Ejemplo práctico en salud
Apoyo a la toma de decisiones	Sistemas que ayudan a clasificar pacientes según la gravedad en servicios de urgencia
Cribado y diagnóstico precoz	Detección automática de cáncer de mama en mamografías o retinopatía diabética en fondo de ojo
Mayor precisión	Interpretación de ECG para identificar arritmias con alta sensibilidad
Ayuda en el pronóstico	Predicción de evolución de tumores basada en análisis de imágenes histopatológicas
Monitorización del paciente	Dispositivos portátiles conectados que alertan sobre signos vitales anómalos en tiempo real
Reducción de costes	Automatización de procesos administrativos y reducción de pruebas innecesarias
Mínimo de errores	Herramientas de revisión automatizada de dosis y contraindicaciones farmacológicas

No obstante, estos avances no están exentos de desafíos relevantes. Uno de los más significativos es el sesgo algorítmico, generado a partir de conjuntos de datos no representativos, lo que puede conducir a errores sistemáticos y a la reproducción de desigualdades estructurales, especialmente en poblaciones vulnerables o subrepresentadas.^{81,92} A estas limitaciones se suman las preocupaciones éticas relacionadas con la privacidad de los datos clínicos, el consentimiento informado y la aceptación de estas herramientas por parte del personal sanitario. Otro aspecto crítico es el uso de modelos altamente complejos y de difícil interpretación, conocidos como “caja negra (black box, en inglés)”, en los cuales, incluso cuando las predicciones son correctas, la imposibilidad de comprender cómo se ha llegado a ciertos resultados plantea dilemas éticos, jurídicos y clínicos, sobre todo en decisiones de salud relevante o que afectan directamente a la vida del paciente.³⁸ En respuesta a estos desafíos, diversas iniciativas regulatorias, como el Reglamento Europeo de IA, han buscado establecer marcos normativos orientados a garantizar la seguridad técnica, la transparencia, la trazabilidad y la equidad en la implementación de estas tecnologías. Comprender estos límites es esencial para contextualizar no solo las promesas, sino también las responsabilidades que acompañan el uso de la IA en el sector salud, en particular en áreas como la atención visual y ocular, donde su integración clínica ha avanzado de forma notable y ofrece ejemplos valiosos para comprender el verdadero alcance de esta transformación.⁶⁹



1.6. IA en salud visual (estado del arte)

La evolución de la IA en el campo de la salud visual y ocular no solo refleja el avance general de las tecnologías digitales aplicadas a la salud, sino que representa uno de los ámbitos donde su potencial se ha materializado con mayor claridad, continuidad e impacto clínico, favorecido por la naturaleza visual de los datos, la existencia de criterios diagnósticos bien definidos y la disponibilidad de grandes bases de imágenes clínicas.⁹⁹ Aunque sus primeras aplicaciones experimentales comenzaron a explorarse a inicios del siglo XXI, fue a partir de 2016 cuando comenzaron a difundirse globalmente los sistemas capaces de detectar retinopatía diabética en fotografías de fondo de ojo con una precisión comparable a la de profesionales especializados, a partir de modelos de aprendizaje profundo desarrollados por el equipo de investigación de Google y validados en poblaciones reales.^{82,100} Este avance, ampliamente referenciado como uno de los primeros hitos clínicos de la IA en oftalmología, dio lugar a una expansión continua de estudios, iniciativas regulatorias y experiencias de aplicación concreta en entornos asistenciales.

Desde entonces, enfermedades como la retinopatía diabética, la degeneración macular asociada a la edad (DMAE), el glaucoma, los errores refractivos, entre otras, han sido foco del desarrollo de modelos capaces de analizar imágenes o datos con alto grado de precisión, predecir riesgos, sugerir derivaciones clínicas o incluso detectar

patrones imperceptibles a la observación humana directa.^{41,80,99,101} Estos avances han posicionado a la oftalmología como un caso ejemplar del uso aplicado de la IA en el ámbito sanitario, tanto en contextos hospitalarios como en estrategias de salud pública, y han otorgado a la salud visual un lugar destacado dentro del ecosistema global de innovación asistida por IA.

1.6.1. Aplicaciones por área en salud de la visión

Con el propósito de facilitar la comprensión del panorama general del uso actual de la IA en salud visual y ocular, se presenta a continuación un resumen segmentado por subáreas, que busca sintetizar este campo desde las perspectivas del tipo de tecnología y su función principal.

a) Retinopatías y fondo de ojo

El análisis automatizado de imágenes de fondo de ojo representa uno de los campos más desarrollados y validados del uso de la IA en salud visual (Figura 1.10), con una trayectoria evolutiva que se remonta a los primeros sistemas de diagnóstico asistido por computadora.¹⁰² Modelos de DL, especialmente las CNN, han sido entrenados para detectar lesiones compatibles con retinopatía diabética, como microaneurismas, exudados o hemorragias, a partir de fotografías retinianas convencionales.^{41,82,101,103} Estos sistemas no solo alcanzan niveles de sensibilidad y especificidad comparables a los de profesionales especializados, sino que también permiten cribados poblacionales a gran escala, reduciendo la necesidad de interpretación clínica directa en fases iniciales. En este contexto, uno de los primeros y más conocidos ejemplos es el sistema validado por el equipo de

Google Health, cuya arquitectura sirvió de base para el algoritmo ‘IDx-DR’, aprobado por la Administración de Alimentos y Medicamentos de los Estados Unidos (*Food and Drug Administration*, FDA) en 2018 como el primer sistema autónomo de IA autorizado para uso diagnóstico en atención visual.^{40,99,100} Desde entonces, se han publicado múltiples experiencias de implementación práctica, incluyendo programas de cribado en farmacias, clínicas móviles y centros comunitarios, especialmente en países de ingresos bajos y medios, donde la escasez de especialistas convierte a estas herramientas en soluciones escalables, eficientes y precisas.^{99,101} Además, se ha documentado el uso creciente de soluciones integradas en dispositivos portátiles, como retinógrafos compactos o adaptadores para smartphones, que permiten capturar imágenes retinianas de forma accesible, facilitando la incorporación de IA en estrategias de atención primaria.^{41,101}




Figura 1.10. Ejemplos reilustrados de retinografías y sus respectivos mapas de activación generados por un modelo de IA. a: Caso de retinopatía diabética con edema macular. b: Caso de oclusión venosa, con antecedentes de fotocoagulación. Adaptada y reilustrada de Li et al.(CC BY 4.0).¹⁰⁴

b) Glaucoma y nervio óptico

El cribado y seguimiento del glaucoma ha sido otro de los campos donde la IA ha mostrado un progreso notable, especialmente gracias al uso de la OCT y fotografías del nervio óptico (Figura 1.11), valiéndose también de técnicas de visión computacional mediante CNN. Modelos entrenados con imágenes estructurales han sido capaces de segmentar automáticamente las capas retinianas, evaluar la relación excavación/disco y detectar patrones de adelgazamiento provocados por daño glaucomatoso, con una precisión comparable a la observación clínica.^{80,105,106} Además, se han desarrollado sistemas para predecir la progresión de la enfermedad, utilizando datos secuenciales de OCT o campos visuales. Algunos algoritmos combinan análisis de imágenes con datos clínicos (como presión intraocular, espesor corneal o antecedentes familiares), proporcionando una valoración del riesgo que orientan en la derivación o en el seguimiento de pacientes sospechosos.^{17,99} Estas herramientas, cada vez más presentes en dispositivos de diagnóstico portátiles o integradas en sistemas de salud digital, no solo optimizan el tiempo de los profesionales, sino que amplían la posibilidad de ofrecer un diagnóstico precoz en escenarios comunitarios o de difícil acceso a una atención oftalmológica especializada.^{99,101}




Figura 1.11. Comparación de ojos sanos y con glaucoma utilizando imágenes de OCT y fondo de ojo, con mapas de relevancia generados por IA. (a–c) Ojo sano; (d–f) primer caso de glaucoma; (g–i) segundo caso de glaucoma. (CC BY 4.0)¹⁰⁷

c) Segmento ocular anterior

Aunque buena parte del desarrollo en IA en salud visual se ha centrado en el fondo de ojo, también se han explorado aplicaciones dirigidas al segmento anterior, particularmente en condiciones que afectan a la córnea, a la superficie ocular y al cristalino. Una de las líneas más desarrolladas se aplica al queratocono, donde diversos modelos de clasificación basados en DL han sido entrenados con imágenes topográficas, permitiendo una detección temprana incluso en

estadios subclínicos. Algunas herramientas combinan información topográfica y tomográfica (Figura 1.12) con técnicas de análisis de patrones para facilitar el cribado en jóvenes y poblaciones de riesgo, como usuarios de lentes de contacto o personas con antecedentes familiares.^{108,109} Además del queratocono, otras alteraciones corneales, como las distrofias, cicatrices posquirúrgicas o de origen infeccioso, han sido objeto de estudios emergentes que utilizan imágenes de alta resolución y algoritmos de segmentación para caracterizar anomalías en la morfología corneal.^{79,110}

Por su parte, en el ojo seco, han comenzado a desarrollarse soluciones que analizan imágenes de la película lagrimal, expresiones glandulares o patrones palpebrales mediante visión computacional. Aunque aún en fase exploratoria, estas propuestas abren nuevas perspectivas para el abordaje objetivo de una condición frecuentemente subdiagnosticada.^{90,111} Finalmente, una de las áreas más consolidadas de aplicación de IA en el segmento anterior se encuentra en el campo de la catarata, tanto para el diagnóstico automatizado en programas de cribado comunitario como para el apoyo en la planificación quirúrgica. Algoritmos basados en imágenes de lámpara de hendidura y fotografías clínicas han demostrado alta precisión en la detección y clasificación de distintos tipos de opacificación del cristalino, lo que puede contribuir a mejorar el acceso al tratamiento en regiones con recursos limitados.¹¹² En contextos quirúrgicos, se han explorado sistemas que integran análisis de imágenes con datos biométricos para asistir en la selección de lentes intraoculares y en la predicción del resultado refractivo.¹¹³




Figura 1.12. Resultados de un sistema de diagnóstico para la detección de queratocono basado en IA, utilizando mapas topográficos corneales. (CC BY 4.0)¹¹⁴

d) Errores refractivos y control de la miopía

La predicción y seguimiento de los errores refractivos, con énfasis especial en la progresión de la miopía (Figura 1.13), se ha convertido en una línea activa de investigación en IA. A medida que la miopía alcanza proporciones epidémicas a nivel mundial, especialmente en edad escolar, se han propuesto opciones para integrar datos biométricos - como la longitud axial, la curvatura corneal y la profundidad de la cámara anterior - con algoritmos predictivos capaces de anticipar el desarrollo o agravamiento del defecto refractivo.^{44,115} Algunos modelos aplican redes neuronales profundas para estimar el riesgo individual de miopía progresiva, contribuyendo así a la selección

de intervenciones clínicas personalizadas y al acompañamiento terapéutico longitudinal del paciente. Además de las herramientas de predicción, también se han investigado modelos que integran datos clínicos longitudinales y factores ambientales para generar predicciones de respuesta al tratamiento, como el uso de atropina o lentes de desenfoque periférico, lo que abre nuevas posibilidades para una gestión más proactiva y personalizada del control de la miopía.⁴⁴

Asimismo, se han explorado aplicaciones móviles y sistemas de cribado automatizado basados en imágenes, que permiten, por ejemplo, capturar reflejos pupilares mediante dispositivos portátiles para estimar posibles errores refractivos. Aunque muchas de estas herramientas aún se encuentran en fase de validación, reflejan una tendencia clara hacia soluciones accesibles y escalables, especialmente dirigidas a poblaciones pediátricas, escolares o en contextos con baja cobertura de profesionales optometristas.⁷⁸




Figura 1.13. Aplicación de IA para predicción del desarrollo de miopía y análisis interpretativo de las características. a/b: Imágenes de fondo de ojo y mapas de resultados asociados a progresión a miopía y miopía alta, respectivamente. c: Representación interpretativa de la influencia de las características individuales. d: Contribución porcentual de cada característica en la predicción. (CC BY 4.0)¹¹⁵

e) Visión pediátrica y binocular

El abordaje de condiciones visuales en población pediátrica también se ha beneficiado del desarrollo de soluciones de IA adaptadas a las particularidades de este grupo etario. En especial, se han desarrollado algoritmos que permiten el cribado de la ambliopía, el estrabismo y de otras alteraciones sensoriomotoras, aplicando técnicas de análisis automatizado de imágenes faciales y registros de vídeo. Estas herramientas emplean redes neuronales profundas entrenadas para detectar patrones de asimetría ocular, desviaciones en la alineación ocular y microvariaciones en los movimientos sacádicos o de fijación, con el fin de identificar precozmente signos sugestivos de disfunción binocular.^{116,117} En el caso de la ambliopía, se han propuesto sistemas que analizan los reflejos corneales y la oclusión pupilar en fotografías tomadas con cámaras convencionales, lo que permite estimar el riesgo de forma no invasiva (sin contacto directo ni necesidad de dilatación pupilar).¹¹⁸ Para la detección del estrabismo se han utilizado redes convolucionales entrenadas con imágenes frontales para identificar ángulos de desviación y anomalías en los reflejos de Hirschberg que alcanzan valores de sensibilidad comparables a las de una evaluación clínica estándar.¹¹⁷

En el ámbito escolar, dispositivos móviles equipados con cámaras y software inteligente han sido implementados de forma experimental para detectar alteraciones en la alineación ocular, reflejos pupilares anómalos y signos indirectos de errores refractivos. Estas tecnologías permiten estrategias de cribado masivo, no invasivas y de bajo costo, que pueden ser integradas en campañas de salud pública infantil. Un ejemplo práctico es el uso de plataformas que capturan vídeos breves

de la mirada infantil mientras el niño sigue un estímulo visual, y luego analizan los patrones de fijación y coordinación ocular mediante visión computacional.^{44,118} Aunque muchas de estas propuestas aún se encuentran en fase de validación, su versatilidad las convierte en alternativas viables para contextos con acceso limitado a atención especializada. Más recientemente, también se han comenzado a explorar enfoques que integran IA en programas de terapia visual y reeducación binocular, mediante plataformas digitales adaptativas y entornos de realidad virtual.¹¹⁹ Estas herramientas permiten ajustar dinámicamente los estímulos visuales en función de la respuesta del usuario, lo que puede potenciar tanto la personalización del tratamiento como la adherencia terapéutica en casos de ambliopía o disfunciones sensoriomotoras persistentes.³⁶

f) Análisis celular y aplicaciones quirúrgicas

Uno de los campos prometedores y aún poco explorados de la IA en salud ocular es su aplicación en el análisis de estructuras celulares y subcelulares mediante técnicas de imagen de alta resolución. Modelos de DL han sido entrenados para procesar imágenes obtenidas por microscopía confocal in vivo, permitiendo la segmentación automática de células de la córnea y la evaluación de alteraciones en el endotelio corneal, como la pérdida celular, el polimegatismo o el pleomorfismo. Esto permite cuantificar parámetros clave y aportar mayor objetividad al diagnóstico de distrofias endoteliales, queratopatías tóxicas o cuantificar el daño postquirúrgico.¹²⁰ Además, algunos estudios han demostrado que los algoritmos de IA también pueden identificar sutiles biomarcadores oculares en imágenes de fondo de ojo, abriendo nuevas posibilidades para la detección precoz de enfermedades oculares y

sistémicas a nivel microscópico o funcional.⁹ Aunque muchas de estas investigaciones aún se encuentran en fase experimental, representan una clara ampliación del alcance de la IA hacia dimensiones microscópicas y moleculares de la salud ocular, con potencial para apoyar tanto la práctica clínica como la investigación biomédica.^{110,121}

La IA también comienza a integrarse en entornos quirúrgicos oftalmológicos, extendiendo su utilidad desde el análisis celular hacia el acompañamiento intraoperatorio.⁸⁴ En procedimientos vítreo-retinianos, por ejemplo, se han desarrollado sistemas de visión computacional en tiempo real que emplean modelos de DL para rastrear instrumentos quirúrgicos y segmentar estructuras anatómicas durante la cirugía, con el fin de asistir al especialista y aumentar la precisión de las maniobras quirúrgicas intraoculares.¹²² Asimismo, otras tecnologías similares están siendo exploradas para su aplicación en cirugías del segmento anterior, donde algoritmos entrenados con grabaciones de vídeo permiten identificar fases críticas del procedimiento e incluso generar anotaciones automáticas con fines educativos.¹²³

g) Educación y asistencia digital

El avance reciente de los modelos generativos y de lenguaje natural ha abierto nuevas posibilidades en el contexto del aprendizaje, la orientación clínica preliminar y la interacción paciente-IA en salud. Algunas plataformas experimentales han comenzado a incorporar *chatbots* basados en modelos de LLMs, capaces de proporcionar explicaciones o responder preguntas sobre síntomas o tratamientos de forma personalizada.⁶² Aunque estos desarrollos aún no se han aplicado específicamente al campo de la salud ocular y aunque se puede debatir sobre la validez de sus respuestas en contextos complejos, estos

recursos pueden ser útiles como apoyo educativo o como herramientas complementarias en entornos con baja alfabetización sanitaria.

Asimismo, en el ámbito de la asistencia visual, la IA ha comenzado a formar parte de soluciones orientadas a personas con baja visión, con el objetivo de facilitar su interacción con el entorno y reforzar la autonomía en contextos cotidianos. Mediante la integración de visión computacional, DL y procesamiento de lenguaje natural, se han desarrollado dispositivos móviles y portátiles capaces de transformar información visual en descripciones sonoras en tiempo real, lo que permite, por ejemplo, la lectura de textos, el reconocimiento de objetos o la orientación espacial mediante interfaces auditivas accesibles.¹²⁴ Algunos enfoques recientes han explorado la adaptación dinámica de estas tecnologías a las características funcionales del usuario, incorporando modelos de redes neuronales que ajustan la respuesta del sistema a cada perfil individual.¹²⁵ Aunque su aplicación clínica directa aún es incipiente, este tipo de innovación evidencia una ampliación del rol de la IA en salud ocular hacia formas de asistencia digital que, más allá del diagnóstico o tratamiento, alineándose con propósitos educativos, compensatorios y de apoyo funcional para suplir o reemplazar ciertas funciones visuales.¹¹⁹

La Tabla 1.4 presenta una síntesis de este bloque, añadiendo el grado de incorporación en dispositivos o contextos asistenciales. Los niveles de adopción fueron estimados de forma referencial, con base en la evidencia disponible en la literatura, como la presencia de validación clínica y el grado de integración reportado en entornos sanitarios reales, sin pretender constituir una revisión en formato sistemático

Tabla 1.4 Síntesis de las aplicaciones actuales de la IA en la salud visual y ocular, organizada según el área, tecnología y nivel estimado de desarrollo, compilada a partir de estudios publicados.^{9, 10, 30, 82, 86, 88, 99, 107, 114, 115, 126–129}

Área	Tecnología principal	Ejemplo aplicación clínica	Estimación del nivel de desarrollo
Retinopatías y fondo de ojo	<i>Redes neuronales profundas (Convolutional Neural Networks - CNN)</i>	Detección automatizada a partir de imágenes de fondo de ojo	Alta
Glaucoma y nervio óptico	<i>Segmentación estructural / modelos supervisados</i>	Análisis de OCT y progresión de daño glaucomatoso	Media-alta
Miopía y errores refractivos	<i>Topografía corneal / aprendizaje profundo</i>	Estimación de riesgo y progresión individual	Media
Segmento ocular anterior	<i>Predicción con datos biométricos / aprendizaje automático</i>	Cribado precoz de queratocono	Media
Ojo seco	<i>Visión computacional / análisis glandular</i>	Evaluación objetiva del síndrome de ojo seco	Baja
Visión pediátrica / visión binocular	<i>Análisis facial / reflejos oculares</i>	Detección no invasiva en campañas escolares	Media
Plataformas educativas / IA generativa	<i>IA multimodal / análisis vascular retiniano</i>	Apoyo al aprendizaje clínico y orientación preliminar al paciente	Baja-media
Oculomics y salud sistémica	<i>Aprendizaje profundo / imagenología celular</i>	Inferencia de enfermedades sistémicas a partir de imágenes del ojo	Baja
Aplicaciones asistivas en baja visión	<i>Modelos de lenguaje (Large Language Models - LLMs) / simulación</i>	Apoyo funcional en navegación, lectura y reconocimiento de objetos	Baja
Análisis celular / biomarcadores	<i>Visión computacional / redes neuronales / procesamiento de lenguaje natural</i>	Predicción y caracterización de células en enfermedades oculares	Baja

1.6.2. Trayectoria y horizonte de la IA en salud visual

Desde la validación de los primeros modelos de IA aplicados a salud visual, este campo ha experimentado una evolución constante, marcada por avances tanto en las capacidades tecnológicas como en los niveles de implementación práctica. La Figura 1.14 se presenta una síntesis cronológica de algunos de los hitos más representativos, elaborada a partir del contenido detallado en el apartado 1.6.1.




Figura 1.14. Representación temporal que ilustra el inicio aproximado de distintas áreas de las ciencias de la visión vinculadas al desarrollo de investigaciones sobre tecnologías basadas en IA, compilada a partir de estudios citados en la sesión 1.6.1 (elaboración propia)

Esta línea de tiempo ofrece una visión general de la evolución del uso de la IA en distintas subáreas de la salud visual, mostrando las fechas aproximadas en las que se presentaron los diferentes desarrollos o las publicaciones más influyentes en cada área, sin pretender constituir una revisión sistemática, sino más bien ofrecer un apoyo visual y contextual de esta evolución.

Más allá de las aplicaciones ya implementadas, la IA continúa abriendo nuevas fronteras en el campo de la salud visual, impulsada por el desarrollo de modelos multimodales, enfoques generativos y capacidades aumentadas de procesamiento de datos en tiempo real. Estas innovaciones no solo buscan optimizar diagnósticos específicos, sino que también amplían el potencial del examen ocular como herramienta de monitorización integral del estado sistémico del organismo.^{8,110}

Entre las propuestas más disruptivas se encuentra el concepto de ‘*oculomics*’ (Figura 1.15), que representa una línea de investigación que considera al ojo como una “ventana” accesible para la detección de enfermedades sistémicas, mediante el análisis de patrones vasculares, microestructurales o celulares en imágenes de retina o del segmento anterior. Modelos entrenados con grandes bases de datos etiquetadas han mostrado capacidad para predecir riesgo cardiovascular, edad biológica, diabetes tipo 2 e incluso deterioro cognitivo y enfermedad de Alzheimer, con grados de precisión comparables a los de pruebas más invasivas o costosas. Tecnologías como la OCT, la angiografía por OCT y la fotografía de fondo de ojo de alta resolución se combinan con algoritmos de DL para identificar marcadores de detección precoz de

estos trastornos, lo que podría redefinir el rol del examen ocular dentro de la atención primaria en el futuro.^{10,129,130}




Figura 1.15. Representación esquemática del concepto de 'oculomics'. (CC BY 4.0)¹⁰

En paralelo, se observa un crecimiento acelerado de sistemas que integran múltiples fuentes de datos, como imágenes clínicas, historial clínico, parámetros biométricos y lenguaje natural, con el objetivo de ofrecer evaluaciones más holísticas y personalizadas, en línea con el paradigma emergente de la IA multimodal (modelos que integran distintos tipos de datos como imágenes, texto, biometría y lenguaje natural).⁸ También se han desarrollado modelos capaces de analizar imágenes de lámpara de hendidura para detectar signos sutiles de

inflamación ocular o evaluar la transparencia corneal en contextos de trauma o edema.¹¹⁶ Además, se exploran plataformas que combinan datos clínicos estructurados con imágenes y antecedentes del paciente, utilizando redes neuronales para generar predicciones diagnósticas o sugerencias terapéuticas automatizadas.¹¹⁰ Aunque muchas de estas soluciones aún se enfrentan a serios desafíos en su validación clínica, interoperabilidad y aceptación profesional, su evolución representa el horizonte para ofrecer una atención visual más conectada, predictiva y centrada en la persona, preparando el terreno para nuevas aplicaciones en contextos específicos como la AVP.

Capítulo
Chapter

2

Fundamentación y planteamiento general

Rationale and general design



2.1. Justificación

La atención visual primaria (AVP) cumple un rol fundamental en la promoción de la salud ocular, la prevención de deficiencias visuales evitables y para resolver las necesidades visuales comunes de la población.^{1,2} Su cercanía con la comunidad y su potencial costo-efectividad la sitúan como un pilar de los sistemas sanitarios modernos, especialmente en contextos donde las desigualdades en el acceso, la escasez de especialistas o la creciente demanda asistencial limitan la cobertura especializada.^{3,5,59} En este contexto, la incorporación de tecnologías digitales se ha consolidado como una estrategia clave para fortalecer la atención en salud y mejorar la equidad en el acceso a los cuidados visuales.^{2,3,21} Por estos motivos, la pertinencia de la presente Tesis Doctoral está respaldada desde los siguientes puntos de vista:

Relevancia: En los últimos años, la expansión de las tecnologías digitales en salud ha abierto nuevas posibilidades para ampliar las capacidades diagnósticas y apoyar la toma de decisiones clínicas en tiempo real.^{11,21,93} En particular, la inteligencia artificial (IA) ha demostrado un alto potencial en el ámbito de la salud visual, especialmente en el análisis automatizado de imágenes retinianas, la clasificación de patologías y la priorización de casos.^{82,86,99,131} Sin embargo, su incorporación en flujos conversacionales interactivos y accesibles aún se encuentra en una etapa incipiente.^{36,37,60}

Oportunidad: El desarrollo de asistentes virtuales basados en IA puede representar una alternativa concreta para guiar a los usuarios y apoyar a los profesionales en tareas rutinarias de cribado, orientación preliminar y clasificación de riesgo.^{17,64,67} Este tipo de herramientas ha sido explorado en otras especialidades, como la salud mental o la atención crónica, con resultados alentadores en términos de usabilidad, aceptabilidad y apoyo a la toma de decisiones clínicas.^{37,66} También se han reportado experiencias positivas en el ámbito de la oftalmología, donde los asistentes virtuales han sido utilizados para educación sanitaria, orientación básica y apoyo inicial ante diferentes síntomas.^{36,37,60,61,128} Sin embargo, su aplicación específica en optometría y AVP continúa siendo limitada.

Viabilidad: Al mismo tiempo, el avance en el almacenamiento de registros clínicos electrónicos y la mayor capacidad técnica para manipular diferentes tipos de datos han permitido generar modelos de IA (campo que se encuentra en pleno y constante desarrollo) capaces de aportar predicciones útiles en escenarios sanitarios, capaces de aportar predicciones útiles en escenarios sanitarios.^{33,42,45,62}

En suma, la Tesis Doctoral se justifica por una combinación entre la relevancia de buscar soluciones y alternativas de apoyo a la salud, la oportunidad generada por las tecnologías actuales y la viabilidad operativa. Además, propone un enfoque innovador e interdisciplinario, que articula saberes provenientes de las ciencias de la visión, la IA y la tecnología digital aplicada a la AVP, con potencial de escalabilidad y aplicación en diversos contextos formativos o asistenciales.



2.2. Hipótesis

El desarrollo de un asistente virtual basado en modelos de IA, entrenado con datos clínicos específicos, puede constituir una herramienta pertinente y factible para apoyar la toma de decisiones en AVP, a partir del análisis de signos, síntomas y resultados de exámenes clínicos



2.3. Objetivos

Objetivo General

Desarrollar y validar un asistente virtual basado en IA para apoyar la toma de decisiones en AVP.

Objetivos específicos

1. Analizar el desarrollo de la investigación en salud digital aplicada a las ciencias de la visión, caracterizando su relación con la atención visual y describiendo las tecnologías propuestas en este ámbito. **Capítulo 3**
2. Analizar la disponibilidad y características de los conjuntos de datos públicos relacionados con las ciencias de la visión. **Capítulo 4**
3. Proponer un modelo de plataforma global para el almacenamiento de datos clínicos, basado en estándares de registros electrónicos de salud y modelos actuales de repositorios. **Capítulo 5**

- 4.** Generar modelos de IA entrenados con datos clínicos optométricos, orientados a apoyar la toma de decisiones en AVP. **Capítulo 6**
- 5.** Desarrollar una aplicación en formato de asistente virtual que integre modelos de IA, facilitando su aplicación en contextos clínicos y educativos. **Capítulo 7**
- 6.** Evaluar la influencia del asistente virtual en la toma de decisiones clínicas en salud visual, así como la percepción de los profesionales sobre su uso. **Capítulo 8**

2.4. Metodología general

La presente Tesis Doctoral presenta un plan metodológico que articula enfoques exploratorios, tecnológicos y aplicados con el fin de alcanzar sus objetivos. Dado el carácter multidisciplinar del tema abordado, la metodología general se organizó en torno a dos bloques complementarios que conforman un proceso progresivo y articulado, según se representa en la Figura 2.1.




Figura 2.1. Representación esquemática de la metodología general de la Tesis Doctoral. El fondo azul indica las acciones vinculadas al enfoque exploratorio, mientras que el fondo amarillo representa las actividades orientadas al enfoque principal. El círculo central (OG) corresponde al objetivo general y los segmentos numerados (1 a 6) identifican los respectivos objetivos específicos, tal como se presentan en la sección 2.3 de este capítulo.

Primer bloque

De carácter exploratorio, se orientó a la comprensión del contexto y a la caracterización del entorno, recursos y condiciones asociadas al uso de tecnologías digitales en el ámbito de la salud visual. Las principales acciones desarrolladas en esta etapa incluyeron:

1. **Estado del arte:** Caracterización de tecnologías en salud digital aplicadas en el cuidado de la visión.

Capítulo 3

2. **Disponibilidad de datos:** Disponibilidad y características de conjuntos de datos clínicos para uso las ciencias de la visión.

Capítulo 4

3. **Estructuras de almacenamiento:** Propuesta de plataforma *big data* para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular.

Capítulo 5

Estas acciones están alineadas con los primeros objetivos específicos de la Tesis Doctoral (1, 2 y 3), y están centradas en comprender y contextualizar el escenario sobre el que se construye la propuesta principal.

Segundo bloque

Se centró en el desarrollo tecnológico y en la validación de una solución basada en IA. Esta fase incluyó actividades dirigidas directamente al objetivo principal, en las cuales se desarrollaron las siguientes acciones:

4. Modelos predictivos: Desarrollo de modelos de IA en AVP.

Capítulo 6

5. Asistente virtual: Desarrollo del prototipo del asistente virtual en AVP.

Capítulo 7

6. Evaluación aplicada: Validación de modelos IA para apoyar la toma de decisiones en salud visual y ocular.

Capítulo 8

Estas acciones se corresponden con los objetivos específicos orientados al desarrollo y validación de la propuesta central (5, 6 y 7), y en conjunto con el primer bloque contribuyen al cumplimiento del objetivo general de la Tesis Doctoral. Cada sección describe en detalle sus propios procedimientos metodológicos, en función de las necesidades particulares de cada objetivo, los cuales se encuentran detallados en sus respectivos capítulos.

Capítulo
Chapter

3

Caracterización de tecnologías en salud digital aplicadas al cuidado de la visión

Characterization of digital health technologies applied to vision care



3.1. Introducción

La tecnología aplicada a la salud es una parte fundamental del desarrollo de este sector, no sólo por la innovación a través de equipos especializados sino también por el apoyo a diferentes procesos y acciones relacionadas con el cuidado de la salud.⁶⁸ Es así que, diferentes avances tecnológicos, como el crecimiento en el uso de aplicaciones para teléfonos inteligentes, algoritmos de inteligencia artificial (IA) o el almacenamiento de datos en la nube, entre otros, al igual que determinados cambios en los hábitos de la población, se han visto reflejados directamente en una readaptación de los servicios de salud.^{13,95} El uso aplicado de diferentes tecnologías de “salud digital” ha provocado un gran interés en los últimos años y se vio amplificado por la pandemia de COVID-19^{14,21} representando un ecosistema que abarca diversas ramificaciones dentro del área de la salud,¹¹ que ha dado lugar a su reconocimiento en el mundo del emprendimiento con el término *Health techs*.²¹

Conceptos elementales de salud digital

La constante evolución del proceso tecnológico dificulta la definición de conceptos definitivos para algunas terminologías, puesto que las taxonomías se proponen o reajustan constantemente de acuerdo con la comprensión de los nuevos procesos desarrollados y/o aplicados. Por ello, se ofrece una definición actual de los términos

ampliamente utilizados en este ámbito para contextualizar y facilitar la comprensión de esta Tesis Doctoral.⁵⁸

Términos como *eHealth* y *mHealth* reflejan el uso de tecnologías de información y comunicación en salud, que van desde plataformas web hasta aplicaciones móviles, con el objetivo de optimizar, personalizar y simplificar los procesos de atención y gestión sanitaria^{22,23}. Por su parte, las aplicaciones de inteligencia artificial (IA) se basan en algoritmos de *machine learning* (ML) o *deep learning* (DL), como por ejemplo redes neuronales, para generar soluciones de soporte o ayuda tanto al diagnóstico como al análisis de datos.^{59,69,73,81,92} Estas soluciones han respaldado con frecuencia en la práctica profesional el uso de la telemedicina y telesalud, facilitando interacciones a distancia entre profesionales de la salud y pacientes, que han mejorado el acceso y ampliado el alcance de los servicios de salud.^{22,23,132} El avance de estas tecnologías está directamente relacionado con la expansión de bases de datos masivas (*big data*)⁴³, que ha sido propiciada por el aumento en la capacidad de almacenamiento y en la recolección de información a través de dispositivos conectados (*IoT* - Internet de las Cosas)³⁵ y servicios de *cloud computing*, que proporcionan la infraestructura necesaria para el almacenamiento y procesamiento de grandes volúmenes de datos.⁷⁷

Dado que las herramientas y tecnologías están en constante desarrollo, su uso y aplicabilidad en el área de la salud es cada vez más común y relevante. Así, además de los conceptos mencionados, se han introducido términos como realidad virtual (sistemas que crean una realidad digital paralela¹³³), “realidad aumentada” (sistemas que

integran el mundo real con componentes digitales¹³⁴) y “*blockchain*” (tecnología de seguridad digital utilizada en sistemas bancarios o criptomonedas) con diversas aplicaciones en salud, como la asistencia, la educación, la formación y la protección de datos.¹³⁵

Salud digital en ciencias de la visión

El uso de diferentes tecnologías para mejorar la salud digital en todo el mundo es cada vez más empleado, y entre las especialidades médicas que más ha participado en esta evolución se encuentra, sin duda, la oftalmología.¹³² El uso de modelos de IA para el diagnóstico de la retinopatía diabética¹³⁶ fue uno de los principales avances a nivel mundial y todavía sirve como ejemplo de desarrollo en esta área, con varios ejemplos a nivel mundial (entre los que destaca el sector *Healthtech* de Google⁸² y otros). Desde entonces, el área de la salud ocular/visual se ha convertido en una de las más prolíficas en investigación e innovación, con numerosas investigaciones en diferentes segmentos de la salud digital aplicando diferentes recursos tecnológicos^{137–141}

En este sentido, el presente capítulo analiza el desarrollo que ha experimentado la investigación en salud digital aplicada a las ciencias de la visión en la década de los años 2012 a 2021, para caracterizar su relación con la atención de la salud visual y ocular y describir las tecnologías propuestas con el fin de actualizar el estado del arte en este ámbito.



3.2. Material y Método

Se realizó una investigación exploratoria-cuantitativa de los estudios publicados en revistas peer-review (evaluadas por pares) e indexadas en la base de datos SCOPUS, que abordarán el uso de tecnologías digitales en salud para el cuidado e investigación de problemas visuales.

Para la búsqueda se utilizaron palabras (en inglés) directamente relacionadas con el área de salud visual, tales como “*ophthalmology*”, “*optometry*”, “*eye care*” y “*vision care*”, combinadas con diferentes términos y variaciones relacionadas con la tecnología de salud digital , tales como “*ehealth*”/“*e-health*”, “*mhealth*”/“*m-health*”, “*big data*”, “*cloud computing*”, “*artificial intelligence*”, “*machine learning*”, “*deep learning*”, “*neural network*”, “*internet of things*”, “*augmented reality*”, “*virtual reality*”, “*blockchain*”, “*telemedicine*” y “*telehealth*”.

La búsqueda incluyó las referencias en los títulos, resúmenes y palabras clave de los diferentes artículos, teniendo como clave de búsqueda inicial completa: (TITLE-ABS-KEY(“*optometry*”) OR TITLE-ABS-KEY(“*ophthalmology*”) OR TITLE-ABS-KEY(“*eye care*”) OR TITLE-ABS-KEY(“*vision care*”)) AND (TITLE-ABS-KEY(“*ehealth*”) OR TITLE-ABS-KEY(“*e-health*”) OR TITLE-ABS-KEY(“*mhealth*”) OR TITLE-ABS-KEY(“*m-health*”) OR TITLE-ABS-KEY(“*big data*”) OR TITLE-ABS-KEY(“*cloud computing*”) OR TITLE-ABS-KEY(“*artificial intelligence*”) OR

TITLE-ABS-KEY("machine learning") OR TITLE-ABS-KEY("deep learning") OR TITLE-ABS-KEY("neural network") OR TITLE-ABS-KEY("internet of things") OR TITLE-ABS-KEY("augmented reality") OR TITLE-ABS-KEY("virtual reality") OR TITLE-ABS-KEY("blockchain") OR TITLE-ABS-KEY("telemedicine") OR TITLE-ABS-KEY("telehealth").

Criterios de inclusión y exclusión: La búsqueda inicial se realizó en enero de 2022 y se encontraron 4488 registros. Los filtros se aplicaron directamente en SCOPUS para poder segmentar la búsqueda según los criterios de inclusión establecidos con las palabras clave. Así, para el periodo de búsqueda se definieron los últimos 10 años desde el 2012 al 2021. Se consideraron únicamente artículos publicados en revistas científicas, en inglés y en etapa final de publicación. Se incluyeron revistas dentro del área temática de medicina, profesiones de la salud y ciencias de la computación. Tras aplicar todos los criterios descritos, se seleccionaron 1252 artículos para su análisis individual.

De estos registros, se excluyeron del análisis detallado los estudios que no estaban directamente relacionados con el objetivo de la búsqueda (n=30) y/o aquellos en los que no fue posible realizar su clasificación a partir de la información mostrada en el resumen, título o palabras clave (n=153). De esta forma, tras aplicar los criterios de exclusión, se seleccionaron un total de 1069 artículos para su posterior análisis.

El esquema general del procedimiento metodológico aplicado en la búsqueda bibliográfica se resume en la Figura 3.1.

Análisis de datos: Los registros finales fueron analizados de forma individual y a través de la información del *título*, *palabras clave* y

resumen para clasificar cada artículo. Para hacerlo los datos fueron tabulados y analizados utilizando el software Microsoft Excel/Access 365 e IBM SPSS Statistics 26.0.

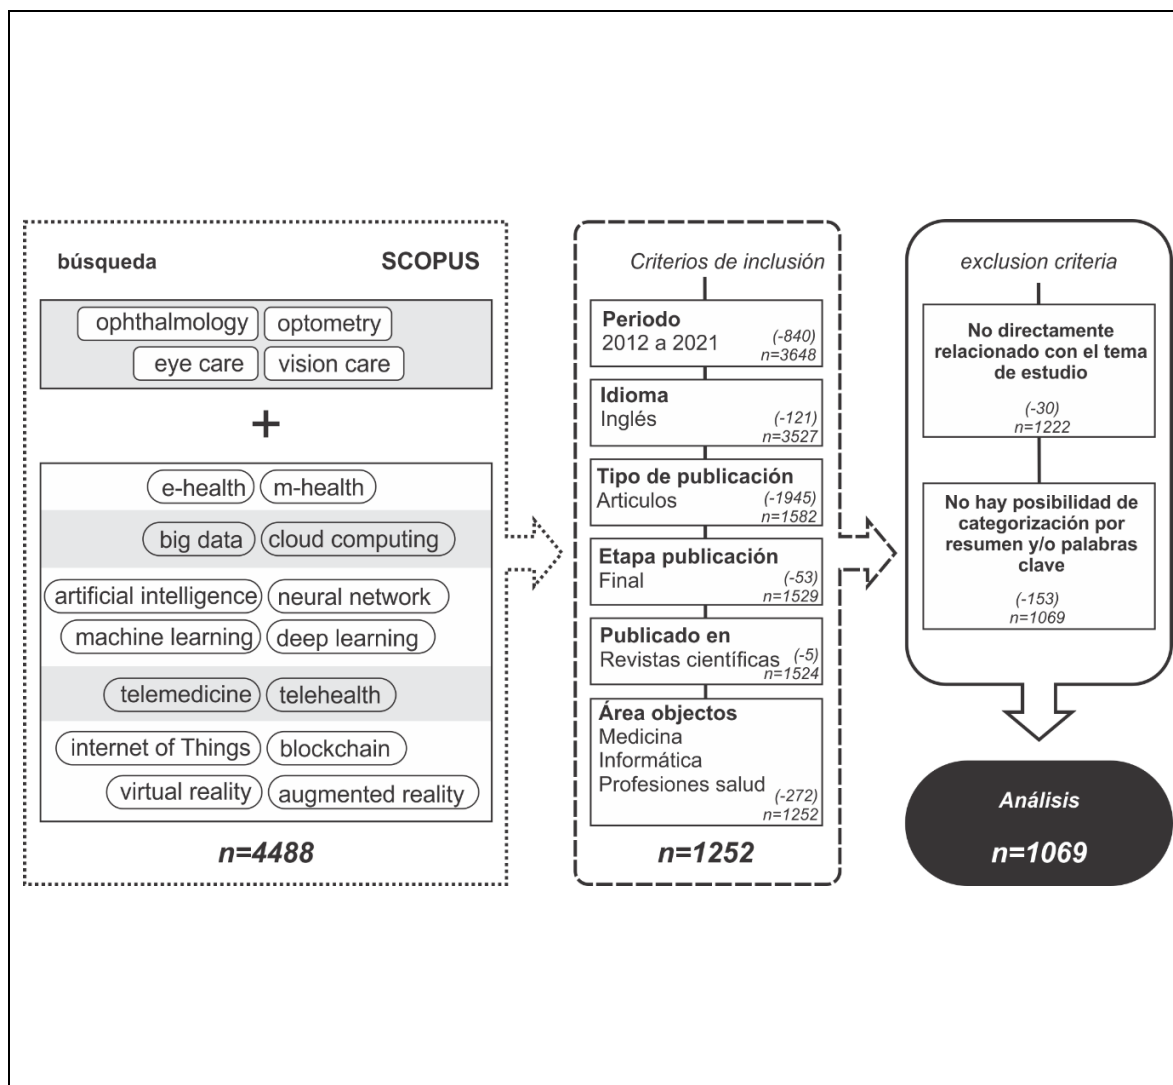


Figura 3.1. Esquema general de la metodología aplicada para realizar la revisión y depurar los resultados de la búsqueda bibliográfica (criterios de inclusión y exclusión).

Para las categorizaciones adoptadas, además de un *análisis descriptivo general*, los estudios fueron clasificados en tres grandes grupos: *en cuanto a la tecnología utilizada*, *en cuanto a salud ocular* y, por último, *respecto al uso de la aplicación*. En la Figura 3.2 se ofrece un esquema detallado del proceso de categorización.




Figura 3.2. Resumen del análisis realizado en los artículos seleccionados para clasificar los resultados de la revisión bibliográfica. IA= Inteligencia artificial; ML= *Machine learning* (Aprendizaje automático); DL= *Deep Learning* (Aprendizaje profundo).

Análisis de los resultados

Se realizó un análisis descriptivo general para presentar las características generales de los artículos analizados, como palabras clave vinculadas, recuento de citas y países involucrados en cada artículo o estudio (según la afiliación de los autores) proporcionando una descripción del número de artículos publicados por año que permite describir la evolución temporal del interés de estas tecnologías dentro de las ciencias de la visión en los últimos 10 años. Para clasificar el país involucrado en cada publicación se contabilizó una sola vez el país si más de un autor estaba afiliado a ese mismo país, mientras que en trabajos con autores de diferentes países, se contabilizaron todos los países involucrados en el trabajo y finalmente en el caso de autores con afiliaciones de diferentes países solo se contabilizó el país de la afiliación principal (la primera).

Clasificación respecto a la tecnología utilizada

Como existen diferentes herramientas de salud digital, se realizó un análisis detallado de la principal tecnología utilizada o propuesta en cada artículo, clasificando cada resultado en cuatro categorías principales: *eHealth*, *Big Data*, *IA* y *otros*. Los integrantes de la categoría *IA* se subclasificaron según el tipo de técnica utilizada como *ML* o *DL*.

Clasificación respecto a la salud ocular

Se han propuesto diferentes tecnologías en salud digital para evaluar diferentes estructuras y/o trastornos oculares. Así, los artículos identificados se clasificaron en dos subgrupos principales, en función de la estructura ocular explorada o de los trastornos oculovisuales abordados.

El primer grupo (*estructura ocular*) incluyó a los estudios que estaban específicamente relacionados con la evaluación de una estructura ocular, que se clasificó en tres categorías según su ubicación anatómica: *polo anterior*, *polo posterior* y *vía visual*. De manera que se realizó un análisis detallado clasificando los resultados según la estructura ocular evaluada en cada artículo. El segundo subgrupo (*trastornos oculovisuales*) incluyó los estudios que estaban relacionados con patologías oculares y disfunciones visuales de manera que se clasificó en cuatro categorías principales: *refracción ocular y visión binocular*, *polo anterior*, *polo posterior* y *otros*. Se realizó un análisis detallado de la condición o patología ocular evaluada, clasificando los resultados de acuerdo con cada condición evaluada.

Clasificación respecto al uso de la aplicación

Las tecnologías de salud digital permiten diversas aplicaciones en el cuidado ocular y de la visión, por lo que los artículos se clasificaron en función de sus aplicaciones prácticas en dos grandes bloques; por un lado, los que abordaban *aplicaciones clínicas* y por otro los que proponían una aplicación *no clínica*.

Los artículos incluidos en el grupo de *aplicaciones clínicas* involucran estudios que evalúan la aplicación de diferentes tecnologías relacionadas con distintos procedimientos en el cuidado ocular, como pueden ser el análisis de la función visual (agudeza visual, sensibilidad al contraste, campo visual, etc.) o el estudio de la anatomía (topo/tomografía corneal, tomografía de coherencia óptica (OCT), etc.). En otras en las que el propósito del estudio era la aplicación de la tecnología en la práctica profesional, se sub-clasificaron en tres categorías adicionales: *apoyo a la toma de decisiones clínicas*, *atención*

visual secundaria/terciaria o finalmente aplicación en *atención visual primaria*. Por su parte, los trabajos que proponían una aplicación no *clínica* incluyeron estudios con diferentes propósitos que no estaban directamente relacionados con la práctica clínico-profesional.

Los temas específicos identificados, para la clasificación en cada subgrupo, fueron contabilizados y presentados para proporcionar una descripción más detallada de las características de los estudios analizados.

Es necesario destacar que todas las categorías y criterios de subclasificación descritos anteriormente no fueron excluyentes, de manera que un mismo estudio pudo ser incluido y categorizado en diferentes subgrupos al mismo tiempo. Por ejemplo, si un trabajo propone un dispositivo (tecnología) de IA para analizar topografías corneales (estructura del ojo) para apoyar las decisiones clínicas (aplicación/uso) en casos de queratocono (trastorno ocular), se clasificó en diferentes categorías. Sin embargo, cuando no fue posible identificar y definir una clasificación específica para el estudio dentro de un grupo determinado, éstos se describieron como *no identificados*.

3.3. Resultados y discusión

Análisis descriptivo general

De los 1069 artículos seleccionados tras refinar la búsqueda, se identificaron 982 (91,86%) que estaban directamente relacionados con el término clave *“ophthalmology”*, mientras que tan solo 20 (1,87%) lo estaban con el término *“optometry”* (Tabla 3.1). Los 67 hallazgos restantes (6,27%) estaban relacionados con términos diferentes como *“eye care”*, *“vision care”* o una combinación de ambos.

Tabla 3.1. Resumen de la información general de los estudios analizados.

Palabras clave	n	%	Citas	n
<i>“ophthalmology”</i>	982	91,86%	Citas totales	21.300
<i>“optometry”</i>	20	1,87%	Promedio de citas	19,92
<i>“eye care”; “vision care”</i>	67	6,27%	Total de estudios citados	883
			Países	n
			Total de países	73
			Países promedio/estudio	1,40

Además, se ha identificado un crecimiento exponencial en los resultados de investigación en este campo en los últimos 10 años, como se detalla en la Figura 3.3-A. Por ejemplo, hace una década (en 2012), solo se identificaron 21 (1,96%) trabajos, mientras en 2021, el número de estudios fue 16 veces mayor (343 artículos) que representan el 32,09% de todos los resultados identificados en una década.

Aunque el incremento ha sido constante, destaca que la gran mayoría de los artículos identificados (n=902; 84,38%) se han publicado en los últimos 5 años (2017-2021). Igualmente, es significativo que más del 50% (n=590; 55,19%) de los trabajos identificados se publicaron entre los años 2021-2022. Este incremento de publicaciones podría explicarse en parte por el impacto de la COVID-19 en la investigación científica que ha obligado a introducir el trabajo a distancia que en el caso de las profesiones sanitarias se apoya ampliamente en el uso de estas tecnologías sanitarias.^{142,143} Sin embargo, los estudios directamente relacionados con el COVID-19 solo representan el 7,8% de los trabajos identificados (n=46; siendo 12 en 2020 y 34 en 2021).

Un total de 883 artículos recibieron citas, con una mediana de 5 citas por trabajo, obteniendo el más citado un total de 2.623 citas. En cuanto a los países de los autores, se identificaron un total de 73, según la información proporcionada por las instituciones afiliadas. Estados Unidos (n=279; 18,58%), China (n=239; 15,91%), India (n=205; 13,65%), Reino Unido (n=87; 5,79%) y Singapur (n=48; 3,20%) ocuparon las cinco primeras posiciones en número de trabajos de investigación, representando el 57,12% de los resultados encontrados (Figura 3.3-B).

Al analizar los datos por continente, los países asiáticos concentraron casi la mitad del total de publicaciones científicas (49,8%), seguidos por América del Norte (22,8%) y Europa (20%), mientras que Oceanía, África y América Sur/Central contribuyeron aproximadamente con un 7% en conjunto (2,3%; 3,1%; 1,7% respectivamente), evidenciando un desequilibrio significativo entre regiones globales (Figura 3.3-C) en este campo de investigación.




Figura 3.3. Resumen del análisis general de datos. **A:** Representación de la producción científica de tecnología digital aplicada a salud visual. Se destacan en negro los estudios que abordaron la temática de la pandemia/COVID-19 (2020-21). **B:** Listado de los 15 países con mayor número de publicaciones, considerando los países de las instituciones afiliadas de autores del estudio. **C:** Contribuciones por países, considerando el total de artículos. Los colores diferencian los continentes dentro del Top 15, y el color gris complementa el resto de la categoría.

Respecto a la tecnología utilizada

En todos los estudios analizados se identificaron las tecnologías utilizadas, que representaron al menos dos tecnologías diferentes (promedio de 2,27). A modo de ejemplo, un estudio sobre aplicaciones para smartphones de apoyo a la salud, que almacena registros clínicos

en la nube y emplea algoritmos de aprendizaje automático, se clasificó igualmente en el subgrupo de *eHealth* (app), *Big data* (datos en la nube) y en IA.

De acuerdo con los resultados presentados en la Tabla 3.2, de forma individual, destacan respecto a los demás resultados el uso de “*mHealth*” (n=651; 60,90%) y “*Deep learning*” (n=616; 57,62%), lo que se puede explicar por el crecimiento de esta tecnología en otras aplicaciones de salud.^{34,144} Por otro lado, “*cloud computing*” (n=3; 0,28%) representa la tecnología menos utilizada en los estudios identificados.

Tras agrupar los resultados en 4 grandes categorías destaca que la IA fue la tecnología más frecuentemente aplicada (n=831; 77,74%), seguida de *eHealth* (n=734; 68,66%), *Big data* (n=147; 13,75%) y Otros (n=89; 8,33%). Dentro del grupo identificado por “Otros”, la tecnología más frecuentemente encontrada fue la “realidad virtual” (n=74; 6,92%), relacionada principalmente con su uso en herramientas de educación y/o simulaciones de diferentes procedimientos. Este uso mayoritario de la IA también se ha descrito en estudios aplicados en otras áreas de salud.⁵⁹

Destaca la gran diferencia en el número de estudios publicados entre 2012-2016 (n=167; 15,62%) y los publicados en los últimos 5 años (2017-2021), que representan el 84,38% del total (n=902), lo que demuestra con claridad la tendencia ascendente en el interés por desarrollar estudios de salud digital relacionados con las ciencias de la visión.

Tabla 3.2. Resumen de la tecnología utilizada en los estudios identificados. El término “% total” se refiere al porcentaje que representa dentro del número total de estudios, mientras que “% grupo” se refiere al porcentaje en cada subgrupo.

Tecnología en salud digital	2012-16			2017-21			Total (12-21)	
	<i>n</i>	% total	% grupo	<i>n</i>	% total	% grupo	<i>n</i>	% total
eHealth	128	11,97%	17,44%	606	56,69%	82,56%	734	68,66%
eHealth	40	3,74%	5,45%	142	13,28%	19,35%	182	17,03%
mHealth	114	10,66%	15,53%	537	50,23%	73,16%	651	60,90%
Big data	35	3,27%	23,81%	112	10,48%	76,19%	147	13,75%
Big data	35	3,27%	23,81%	109	10,20%	74,15%	144	13,47%
Cloud computing	0	0,00%	0,00%	3	0,28%	2,04%	3	0,28%
IA	100	9,35%	12,03%	731	68,38%	87,97%	831	77,74%
Machine Learning	39	3,65%	39,00%	229	21,42%	31,33%	268	25,07%
Deep Learning	50	4,68%	50,00%	566	52,95%	77,43%	616	57,62%
No identificado	23	2,15%	23,00%	77	7,20%	10,53%	100	9,35%
Otros	29	2,71%	17,37%	60	5,61%	67,42%	89	8,33%
Internet de las cosas	1	0,09%	0,60%	7	0,65%	7,87%	8	0,75%
Realidad aumentada	4	0,37%	2,40%	6	0,56%	6,74%	10	0,94%
Realidad virtual	25	2,34%	14,97%	49	4,58%	55,06%	74	6,92%
Blockchain	0	0,00%	0,00%	0	0,00%	0,00%	0	0,00%
Total	167	15,62%		902	84,38%		1069	100%

Al subdividir los datos de los últimos 5 años en 2017-2019 (prepandemia) y 2020-2021 (post pandemia), se observa claramente la expansión del número de trabajos publicados, especialmente los realizados con tecnologías de *eHealth* y de IA (Figura 3.4-A), posiblemente ligeramente influenciado por las necesidades generadas a raíz de enfrentar la pandemia mundial (COVID-19) para buscar soluciones de soporte remoto para proporcionar servicios de atención sanitaria, que ha podido estimular el desarrollo de más aplicaciones de

estas tecnologías en el cuidado de la salud ocular.¹⁴⁵ A partir de 2017, se produjo un aumento de las referencias al aprendizaje profundo (Figura 3.4-B), lo que ayudó a que la tecnología de IA liderara los estudios identificados, probablemente influenciada por el gran impacto del trabajo sobre el uso de la IA para el diagnóstico de la retinopatía diabética publicado en 2019, que ha podido provocar el aumento en este área.^{82,146} Posteriormente, en 2020-2021 ha continuado el crecimiento, evidenciando el alto desarrollo del uso de la tecnología de salud digital en las ciencias de la visión.^{17,145}




Figura 3.4. Evolución de las tecnologías aplicadas en los estudios identificados. **A:** Tipos de tecnologías utilizadas. **B:** Tipos de técnicas de IA empleadas.

Dentro de las referencias que emplearon IA, en 731 estudios (87,96%) se pudo clasificar el tipo de técnica empleada, segmentándose en dos grandes grupos: *machine learning* y *deep learning*, entre los que este último también incluye referencias al uso de redes neuronales. Así, *deep learning* representa el 74,12% (n=616) de los estudios identificados relativos al uso de la IA, mientras que *machine learning*

supone casi un tercio, con un 32,25% (n=268) de los trabajos identificados. Conviene destacar que ambas técnicas pueden utilizarse de forma conjunta. Los resultados encontrados se pueden explicar por la gran cantidad de estudios centrados en el análisis de imágenes, como retinografías, en los que el *deep learning* es la técnica utilizada para su análisis complejo.¹⁴⁴ En cuanto a la evolución de su uso a lo largo de los años, se ha reducido el uso de *machine learning* y técnicas de IA más sencillas, a diferencia de lo que ocurría con técnicas más complejas, como *deep learning/neuronal networks* (redes neuronales).

Acerca de salud ocular

Los estudios se caracterizaron según las estructuras/segmentos oculares analizadas, si bien se evaluaron varios problemas oculares de forma conjunta en muchos estudios. Más de dos tercios (n=728; 68,10%) de las investigaciones identificadas con tecnología en salud digital y ciencias de la visión se relacionaron con estructuras del segmento posterior, mientras que casi el 11% se dedicó a explorar el polo anterior (n=116; 10,85%) y por último una minoría de trabajos (n=42; 3,93%) se dedicaron a explorar estructuras relacionadas con la vía visual, tal y como se ilustra en la Figura 3.5-B.

Al analizar específicamente las estructuras evaluadas en el polo anterior, destacan la córnea y el cristalino con 41 trabajos (35,34%) y 39 (33,62%), respectivamente. Por su parte las células ganglionares (n=29; 69,05%), seguidas de los fotorreceptores (n=17; 40,48), fueron los más frecuentemente investigados en la vía visual (Tabla 3.3). Sin embargo, se destacó el número de trabajos relacionados con la retina (n=679), que se suponen el 93,27% de todos los estudios relacionados con el segmento posterior, tal y como muestra claramente la Figura 3.5-A.

Tabla 3.3. Resumen de las estructuras oculares relacionadas con la aplicación de tecnología empleada en los estudios identificados.

	Estructura ocular	<i>n</i>	Total %	Grupo %
Polo anterior n=116 (10.85%)	Córnea	41	3,84%	35,34%
	Cristalino	39	3,65%	33,62%
	Pupila	21	1,96%	18,10%
	Iris	18	1,68%	15,52%
	Párpado	9	0,84%	7,76%
	Cámara anterior	8	0,75%	6,90%
	Lágrima	7	0,65%	6,03%
	Conjuntiva	6	0,56%	5,17%
	Esclera	5	0,47%	4,31%
	Pestañas	1	0,09%	0,86%
	Humor acuoso	1	0,09%	0,86%
	Cuerpo ciliar	1	0,09%	0,86%
Polo posterior n=728 (68.10%)	Retina	679	63,52%	93,27%
	Disco óptico	101	9,45%	13,87%
	Nervio óptico	67	6,27%	9,20%
	Coroides	41	3,84%	5,63%
	Vítreo	31	2,90%	4,26%
Vía visual n=42 (3.93%)	Células ganglionares	29	2,71%	69,05%
	Fotorreceptores	17	1,59%	40,48%
	Córtex visual	5	0,47%	11,90%
	Células bipolares	4	0,37%	9,52%
	Quiasma óptico	1	0,09%	2,38%
	Núcleo geniculado lateral	1	0,09%	2,38%
No identificadas		271	25,35%	




Figura 3.5. Descripción de las estructuras/segmentos oculares identificados en los estudios analizados. **A:** Estructuras oculares ordenadas en orden de mayor a menor. **B:** Agrupación de estructuras oculares por subgrupos.

En cuanto a las enfermedades o trastornos oculares relacionados (Tabla 3.4), los resultados siguen la misma tendencia, con más de la mitad ($n=606$; 56,50%) de los estudios de tecnología de salud digital para la salud visual/ocular dirigidos a enfermedades del segmento posterior. La pequeña reducción en los datos de los estudios y la clasificación por segmento posterior se puede explicar por el hecho de que algunos temas tienen referencias conjuntas, como la miopía, que fue segmentada para fines de estudio, dentro del grupo de problemas refractivos; sin embargo, muchos de estos estudios también hacen referencia a la estructura de la retina.

Tabla 3.4. Descripción de las enfermedades oculares y disfunciones visuales identificadas en los estudios analizados.

Trastornos oculovisuales		n	total %	grupo %
Refracción ocular y visión binocular	Miopía	27	2,53%	36,49%
	Estrabismo	16	1,50%	21,62%
	Ambliopía	12	1,12%	16,22%
	Error de refracción	11	1,03%	14,86%
	Convergencia	7	0,65%	9,46%
	Astigmatismo	6	0,56%	8,11%
	Alojamiento	5	0,47%	6,76%
	Divergencia	5	0,47%	6,76%
	Tropia	4	0,37%	5,41%
	Presbicia	2	0,19%	2,70%
	Hipermetropía	1	0,09%	1,35%
Polo anterior	Catarata	100	9,35%	86,21%
	Conjuntivitis	9	0,84%	7,76%
	Queratocono	8	0,75%	6,90%
	Ojo seco	7	0,65%	6,03%
	Uveítis	3	0,28%	2,59%
Polo posterior	Retinopatía diabética	298	27,88%	49,34%
	Glaucoma	253	23,67%	41,89%
	DMAE	74	6,92%	12,25%
	Edema macular	57	5,33%	9,44%
	Retinopatía (sin clasificar)	43	4,02%	7,12%
	Neuropatía óptica	20	1,87%	3,31%
	Oclusión de la vena	16	1,50%	2,65%
	Maculopatía	14	1,31%	2,32%
	Retinitis pigmentosa	14	1,31%	2,32%
	Desprendimiento de retina	12	1,12%	1,99%
	Atrofia geográfica	11	1,03%	1,82%
	Coriorretinopatía	6	0,56%	0,99%
	Edema de papila	5	0,47%	0,83%
	Retinopatía hipertensiva	4	0,37%	0,66%
Otros	Cáncer	11	1,03%	73,33%
	Esclerosis múltiple	5	0,47%	33,33%
	Melanoma	2	0,19%	13,33%
	Alergia	1	0,09%	6,67%
No identificado		356	33,30%	

Como se puede observar en la Figura 3.6-A, las enfermedades del segmento posterior, fueron las más exploradas en los estudios analizados, destacando las relacionadas con la retina, más

concretamente la retinopatía, que representó casi un tercio de los estudios encontrados (32,30% del total), con 345 ocurrencias (57,11% en el subgrupo), siendo en su mayoría los estudios sobre retinopatía diabética (n=298; 49,34%). Estos resultados fortalecen nuevamente el enorme impacto de las primeras investigaciones relacionadas con el diagnóstico de la retinopatía diabética mediante IA (*deep learning*), sirviendo de ejemplo en la aplicación de la tecnología en el área de la salud visual.^{24,34}




Figura 3.6. Descripción de los trastornos oculovisuales identificados en los estudios analizados. **A:** Trastornos oculovisuales descritos por orden de mayor a menor. **B:** Agrupación de trastornos oculovisuales por subgrupos.

En segundo lugar, se encuentran las enfermedades del segmento anterior (n=116; 10,85%), en el que destacaron los estudios en cataratas, (n=100; 81,21%) que fueron la 3ª condición más frecuente (9,35%). Por su parte, la *refracción ocular y la visión binocular* obtuvieron 74 hallazgos representando el 6,92% de todos los estudios analizados. Finalmente, el grupo *Otros*, incluyó enfermedades que no encajaban en los subgrupos anteriores, representó el 1,40%, con 15 estudios identificados (Figura 3.6-B).

El análisis concreto del grupo de refracción *ocular y visión binocular* encontró que los estudios para la miopía destacaron con un 36,49% (n=27) representando la 6ª posición (2,53%) entre los problemas de visión encontrados (Figura 3.6-B). El estrabismo, con 16 hallazgos, seguido de la ambliopía con 12, fueron el trastorno oculomotor y del desarrollo encontrados con mayor frecuencia, representando el 21,62% y 16,22% de participación en su subgrupo.

Cabe destacar que muchos artículos abordan estructuras y problemas oculares/visuales de forma conjunta, ya que una misma solución tecnológica suele diseñarse como alternativa para más de un problema visual, lo que explica la repetición en las referencias encontradas. Sin embargo, en 271 (25,35%) de los estudios analizados no fue posible identificar la estructura del ojo y en 356 (33,30%) no fue posible identificar qué problemas oculares estaban asociados al estudio, lo que demuestra la dificultad de segmentación de los datos. Sin embargo, este enfoque podría ser útil para proporcionar una descripción actual acerca del uso de estas tecnologías en salud ocular a lo largo de la última década.

Respecto al uso de la aplicación

Las diferentes aplicaciones (clínicas o no) de los resultados de los estudios encontrados se describen en la Tabla 3.5. La gran mayoría de los estudios identificados pueden tener alguna forma de uso o aplicación clínica (n=1002; 93,73%), mientras que los estudios no clínicos representaron 536 informes (50,14%) y en 24 estudios (2,25%) no fue posible identificar la aplicación de sus resultados.

Tabla 3.5. Tipos de aplicabilidad práctica de los estudios evaluados.

Tipo de uso	Subclasificaciones		n	% total	% grupo
Clínico n=1002 (93,73%)	Apoyo a la toma de decisiones clínicas n=952 (95,01%)	Diagnóstico	506	47,33%	53,15%
		Análisis	479	44,81%	50,32%
		Clasificación	328	30,68%	34,45%
		Control	301	28,16%	31,62%
		Evaluación	187	17,49%	19,64%
		Medición	129	12,07%	13,55%
		Conducta	115	10,76%	12,08%
		Predicción	92	8,61%	9,66%
		Seguimiento	47	4,40%	4,94%
		Monitorización	45	4,21%	4,73%
		Localización	29	2,71%	3,05%
		Pronóstico	18	1,68%	1,89%
	Atención visual secundaria y terciaria n=692 (69,06%)	Cribado	225	21,05%	32,51%
		Tomografía	212	19,83%	30,64%
		Retinografía (fondo del ojo)	187	17,49%	27,02%
		Tratamiento (no especificado)	173	16,18%	25,00%
		Quirúrgico	95	8,89%	13,73%
		Tonometría	56	5,24%	8,09%
		Terapia genética	44	4,12%	6,36%
		Oftalmoscopia	11	1,03%	1,59%
	Atención visual primaria n=153 (15,27%)	Agudeza visual	103	9,64%	67,32%
		Campo visual	55	5,14%	35,95%
		Baja visión	11	1,03%	7,19%
		Rehabilitación	7	0,65%	4,58%
		Lentes de contacto	4	0,37%	2,61%
Anteojos		4	0,37%	2,61%	
No clínico n=536 (50,14%)	Normalización	274	25,63%	51,12%	
	Telemedicina	226	21,14%	42,16%	
	Gestión	132	12,35%	24,63%	
	Educación	104	9,73%	19,40%	
	Epidemiológico	62	5,80%	11,57%	
	No identificado	24	2,25%		

El análisis detallado del grupo de uso clínico mostró que la mayoría de las investigaciones buscaron soluciones para apoyar la toma de decisiones clínica ($n=952$; 95,01%), seguido de los estudios que se refirieron a prácticas dirigidas a la atención secundaria y terciaria, con 692 artículos (69,06%), y finalmente, los estudios

relacionados con actividades dirigidas a la atención primaria de la visión, con un 15,27% (n=153) de participación (Figura 3.7-A) suponen el menor grupo de estudios. Estos resultados sugieren que la gran cantidad de estudios dirigidos a la práctica clínica, especialmente en la toma de decisiones, represente una línea de investigación muy fuerte dentro de la IA para predecir resultados clínicos y así apoyar a los profesionales en la toma de decisiones.³⁸

Las tecnologías de salud digital se han caracterizado por servir de apoyo y asistencia a los profesionales en su toma de decisiones.¹⁴⁷ Así, la categoría apoyo a la toma de decisiones clínica se subdividió en diferentes tipos de apoyo en los que la tecnología puede ayudar y que también pueden aparecer de forma conjunta en el mismo trabajo. De esta forma, la Figura 3.7-B demuestra que las aplicaciones orientadas a apoyar un diagnóstico (n=506; 53,15%) fueron las más comunes, seguidas de cerca por las herramientas de análisis (n=479; 50,32%), clasificación (n=328; 34,45%) y control (n=301; 31,62%). Cabe destacar que los trabajos fueron clasificados según se mencionaba en su contenido, lo que supuso que en muchas ocasiones terminaran concurriendo en más de una categoría, por lo que es comprensible que el término “predicción” haya aparecido con menos referencias, ya que es razonable que se presente de forma oculta en estudios que se enfocaron en el diagnóstico, pronóstico y manejo.

Dentro del grupo de trabajos dirigidos a la atención secundaria y terciaria de nivel visual, se encontraron 225 estudios de cribado, que representan el 32,51% en este grupo. Esta actividad se incluyó en este subgrupo al estar relacionada con el cribado de patologías oculares complejas. Estos datos se corroboran con los hallazgos encontrados

para la tomografía 212 (30,64%) y la retinografía (fondo de ojo) 187 (27,02%), sugiriendo una vez más que las estructuras del polo posterior son las más investigadas hasta la fecha.^{148,149}




Figura 3.7. Relación de la aplicación de la tecnología de salud digital en los estudios analizados. **A:** Aplicación clínica y no clínica. **B:** Detalle de la aplicación clínica destinada a apoyar la toma de decisiones.

Respecto a la subcategoría de estudios centrados en procedimientos relacionados con la atención visual primaria, el referente principal fue la agudeza visual, con 103 estudios identificados (67,32% de este grupo). Por otro lado, las menciones a lentes de contacto y gafas fueron aquellas en las que menos investigaciones asociadas se encontraron, ambas con 4 hallazgos (2,61%), llamando la atención el bajo número de estudios en optometría y actividades de atención primaria, en contraste con los otros grupos identificados.

Finalmente, en el grupo de uso no clínico, se identificaron los propósitos generales de los diferentes estudios. Así, destacan los procesos relacionados con la estandarización (estándares en identificación y reconocimiento de datos) y la telemedicina, con 274 (51,21%) y 226 (42,16%) estudios respectivamente. Para los primeros, se destaca principalmente la búsqueda por conocer, dominar y establecer estándares de referencia para validar algoritmos de IA, lo que sugiere un proceso de evolución de los estudios en este campo. En cuanto a los hallazgos sobre telemedicina o telesalud, cabe destacar que tuvieron su mayor impacto en los últimos dos años (n=110), coincidiendo con la pandemia, donde destacaron el número de estudios en esta área.¹⁵⁰

Limitaciones del estudio

La principal limitación de esta revisión está relacionada con la evaluación de la información incluida en el resumen, título y palabras clave de los estudios analizados que pudieron no incluir con suficiente detalle todos los aspectos concretos sobre cómo se realizó el estudio y podrían, por tanto, afectar a las clasificaciones realizadas de los artículos en caso de haber identificado erróneamente la información de

algún trabajo. Este aspecto, también puede justificar el número relativamente bajo de artículos identificados en la búsqueda bibliográfica realizada. También es posible que los manuscritos sólo incluyan la descripción de los distintos tipos de algoritmos empleados, lo que dificulta su identificación concreta. Además, artículos diferentes podrían tener distintas áreas de estudio (salud/informática) y emplear distinta terminología, lo que dificultaría su comparación o clasificación.

Perspectivas futuras

Considerando que este estudio se centró a publicaciones entre 2012 y 2021, es razonable plantear cómo han evolucionado desde entonces hasta el momento de redacción de esta tesis doctoral los estudios de investigación en este campo. Sin la intención de realizar un análisis detallado o exhaustivo, pero con el propósito de ilustrar cómo se ha continuado desarrollándose esta área, se ha realizado una consulta idéntica a la realizada en este estudio (mismas palabras clave, criterios y base de datos), incluyendo los años 2022 a 2024 (hasta noviembre). Esta búsqueda ha identificado 480 estudios en 2022, 516 en 2023 y 545 en 2024, como se muestra en la Figura 3.8, lo que sugiere que, considerando únicamente el número de estudios publicados -sin un detalle concreto de su contenido-, este tema sigue siendo ampliamente investigado, con un incremento que continúa siendo exponencial desde el año 2021 (último año incluido en el trabajo original), si bien parece que muestra una desaceleración desde 2022.




Figura 3.8. Número de publicaciones encontradas en este estudio con los hallazgos preliminares correspondientes a 2022 a 2024 (* hasta noviembre).

Cabe destacar que probablemente los criterios de búsqueda deban actualizarse, ya que nuevas tecnologías o aplicaciones, como los modelos de lenguaje de gran escala (LLM), IA generativa, *ChatGPT*, entre otros, no fueron incluidos en la revisión original (por no estar disponibles en ese momento), pero probablemente serán considerados en estudios de investigación que deberán formar parte de análisis futuros. En resumen, parece que este tema sigue siendo un campo de investigación dinámico y relevante en ciencias de la visión.

3.4. Difusión

Este capítulo se publicó en open-access en la edición especial “*Artificial Intelligence, Data Science and E-health in Vision Research and Clinical Activity*”, del Journal of Optometry en 2022 (Figura 3.9).

Stuermer L, Martin R. **Characterization of technologies in digital health applied in vision care**, J. Optom. 2022;15; S70-81. doi: 10.1016/j.optom.2022.09.005 (Factor de impacto: 2,3 – Q2 SCIE).



Resultados preliminares se presentaron en el congreso OPTOM 2021 en formato póster, con un análisis de 5 años (2015-2019) en la base PubMed. Aceptado para la edición 2020, debido a la pandemia de COVID-19, fue comunicado en la edición online de 2021 (Figura 3.10).

26º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica - OPTOM2021. Comunicación Póster: **Investigación sobre salud visual empleando e-health, big data e inteligencia artificial aplicada**. Stuermer L, Braga S, Martín R. - al 28 de mayo de 2021. (España).



Conscientes de la posible influencia de la pandemia en el objeto de estudio, se amplió a un período de 10 años utilizando la base de datos SCOPUS para no quedar limitados solo al área de la salud. El estudio previo permitió mejorar las estrategias de revisión, lo que facilitó un estudio de calidad y su publicación en el *Journal of Optometry*.



Figura 3.9. Detalle de la primera página del artículo publicado en *Journal of Optometry*.



Figura 3.10. Detalle del poster presentado en 'OPTOM 2021 Online', con una versión preliminar del estudio.

Disponibilidad y características de conjuntos de datos clínicos para uso las ciencias de la visión

Availability and characteristics of clinical data sets for use in vision sciences



4.1. Introducción

La mayoría de las investigaciones aplicadas en salud se llevan a cabo recopilando datos que son analizados para extraer las conclusiones adecuadas según cada investigación. Los avances en la ciencia de datos han permitido el análisis de grandes volúmenes de datos (*big data*)⁴², como recopilados previamente en estudios clínicos o los datos registrados en sistemas de salud, propiciando que este tipo de análisis de *big data* se convierta en una poderosa herramienta para acelerar la producción científica de manera ágil y económica.¹⁵¹

El campo de la salud visual y ocular también se ha beneficiado significativamente del acceso a grandes volúmenes de datos^{152,153}, posibilitando desde estudios epidemiológicos hasta la modelación de algoritmos de inteligencia artificial para diagnóstico y cribado de diferentes enfermedades,^{44,154,155} como se aborda en el capítulo 3. Estos datos se recogen y/o registran en diversos formatos (imágenes médicas, etc.) y pueden provenir de múltiples fuentes, como bases recolectadas en investigaciones previas, exámenes o historias clínicas electrónicas (*Electronic Health Records*, EHR), que son puestos a disposición pública por diversas instituciones y plataformas digitales.^{16,54} Así, el acceso de investigadores y desarrolladores a estos conjuntos de datos desempeña un papel relevante en la democratización de la información y el fomento de la investigación aplicada.^{156,157}

No obstante, la disponibilidad y la variabilidad en los formatos y características de los conjuntos de datos clínicos plantean desafíos significativos.^{158,159} Entre estos se incluyen limitaciones y costos de acceso, dificultades de interoperabilidad, falta de estandarización e incluso problemas asociados al volumen y la calidad del contenido.¹⁶⁰ Además, algunos estudios previos destacan que la ausencia de metadatos consistentes y de documentación clara puede reducir la utilidad de estos conjuntos de datos en investigación, sin olvidar que existen cuestiones éticas relacionadas con su accesibilidad y uso por determinar y clarificar.^{56,161}

Ante estos desafíos, resulta fundamental comprender las características y limitaciones de estos recursos para garantizar un acceso adecuado y su óptimo aprovechamiento en futuras investigaciones aplicadas y/o desarrollos tecnológicos. Por ello, el objetivo de este capítulo es analizar la disponibilidad de los conjuntos de datos públicos relacionados con las ciencias de la visión, así como identificar sus formatos, tipos y principales características.



4.2. Material y Método

En este trabajo se adoptó un enfoque cuantitativo, utilizando herramientas de búsqueda en línea para identificar y analizar los conjuntos de datos relacionados con la salud visual y ocular disponibles para investigación o desarrollo de soluciones tecnológicas.

La búsqueda se realizó en la plataforma *Google Data Set Search* (Google LLC, EE. UU., datasetsearch.research.google.com), diseñada específicamente para localizar conjuntos de datos en internet, con los siguientes *criterios de búsqueda*. Se usaron como palabras clave “Optometry”, “Ophthalmology” y “Eye care”, incluyendo resultados en el período comprendido entre enero de 2019 y septiembre de 2021. Se excluyeron bases de datos duplicadas o aquellas que no guardaban relación directa con la temática de salud visual.

El análisis de los resultados fue gestionado en Microsoft Excel (Microsoft Corporation, EE. UU., microsoft.com/microsoft-365/). Los conjuntos de datos recuperados fueron refinados y clasificados según su formato, origen (fuente que proporciona el conjunto de datos), situación de acceso (acceso libre) y el perfil de los datos. Además, se analizaron los tipos de uso y, en los datos clínicos, se subclasificaron por nivel de atención en salud y su relación con la salud ocular, como se muestra en la Figura 4.1.




Figura 4.1. Resumen general de la metodología aplicada en la búsqueda realizada.

Los formatos obtenidos (tabla, documento, imagen, texto, archivo u otros) corresponden a filtros preexistentes disponibles en la herramienta *Google Data Set Search*, facilitando la categorización inicial de los conjuntos de datos identificados. El formato de "tabla" se refiere a datos estructurados en filas y columnas, comúnmente en formatos como Excel o CSV; el formato "documento" engloba archivos en texto

plano o procesadores de texto como Word o PDF; el formato "imagen" incluye fotografías o gráficos relacionados con datos visuales; el formato "texto" hace referencia a contenidos en formato textual sin estructura tabular, como informes o descripciones; el formato "archivo" abarca formatos comprimidos o paquetes de datos (como ZIP, RAR, etc.); y finalmente el formato "otros" agrupa formatos menos comunes o que no encajan en las categorías anteriores.

En cuanto a la clasificación por tipos de uso, los conjuntos de datos fueron subclasificados en seis categorías: General, Comercial, Tecnología, Educación, Salud y Clínico, basándose en el nombre y la descripción de cada base de datos. El conjunto de datos "General" incluyó datos de uso amplio o no específicos; el "Comercial" aquellos orientados a servicios o productos; en el de "Tecnología" se agrupan los relacionados con innovaciones tecnológicas; y en "Educación" los dirigidos a actividades formativas. Por su parte el conjunto "Salud" abarcó datos vinculados a aspectos generales del bienestar y servicios sanitarios, mientras que el conjunto "Clínico" se restringió a datos directamente aplicables en contextos diagnósticos, terapéuticos o de atención médica especializada. Es relevante señalar que un mismo conjunto de datos podía pertenecer a más de una categoría, dependiendo de su propósito y su alcance.

Los datos clasificados como "Clínicos" fueron además segmentados según su relación con estructuras y/o patologías oculares, así como por el nivel de atención en salud al que estaban asociados. La atención primaria incluye servicios básicos de prevención, promoción y diagnóstico temprano mientras que la atención secundaria abarca cuidados más especializados, como el tratamiento de patologías

específicas y finalmente la atención terciaria comprende servicios de alta complejidad, como intervenciones quirúrgicas avanzadas o el manejo de enfermedades oculares graves. Al igual que ocurre con la agrupación general de los conjuntos de datos, en este caso también es importante destacar que un mismo conjunto de datos podía asociarse a más de un nivel de atención, dependiendo de la amplitud y especificidad de su contenido.

4.3. Resultados y discusión

Se identificaron 432 conjuntos de datos, de los cuales se excluyeron 70 (28 duplicados y 42 irrelevantes), quedando un total de 362 conjuntos de datos registrados y analizados (Tabla 4.1).

Tabla 4.1. Resumen de los conjuntos de datos encontrados en *Google Data Set Search* relacionados con la salud visual.

BÚSQUEDAS	<i>"optometry"</i>		<i>"ophthalmology"</i>		<i>"eye care"</i>		TOTAL
	n	%	n	%	n	%	n
2019	15	13,4%	62	55,4%	35	31,3%	112
2020	21	15,3%	57	41,6%	59	43,1%	137
2021	18	9,8%	72	39,3%	93	50,8%	183
ENCONTRADO	54	12,5%	191	44,2%	187	43,3%	432
DOBLE	4	14,3%	8	28,6%	16	57,1%	28
IGNORADO	6	14,3%	23	54,8%	13	31,0%	42
ANALIZADO	44	12,2%	160	44,2%	158	43,6%	362

De los 362 conjuntos de datos analizados, el 44,2% se localizaron mediante la palabra clave *"ophthalmology"*, siendo esta la que aportó el mayor número de registros (160), seguida por *"eye care"* (43,6%) y *"optometry"* (12,2%), como se muestra en Figura 4.2-A.




Figura 4.2. Resumen de los hallazgos: formato, fuentes y acceso de los conjuntos de datos. **A:** Conjuntos de datos encontrados según la palabra clave. **B:** Conjuntos de datos con acceso libre, segmentados por la palabra clave. **C:** Número de fuentes únicas, segmentados por la palabra clave. **D:** Formatos de los conjuntos de datos encontrados.

Estos resultados reflejan una marcada diferencia en la disponibilidad de datos, con una mayor proporción asociada a términos relacionados con la oftalmología, probablemente debido al desarrollo avanzado en esta área.¹⁶² Esta tendencia se ve reforzada por los datos de la Tabla 4.2, que resume la descripción de las bases de datos encontradas, destacando sus características generales, formato y perfil.

Tabla 4.2. Resumen descriptivo de las bases de datos encontradas con diferentes palabras clave, destacando sus características generales, formato y perfil.

CARACTERÍSTICAS	<i>"optometry"</i>		<i>"ophthalmology"</i>		<i>"eye care"</i>		TOTAL	
	n	%	n	%	n	%	n	%
GENERAL								
<i>Acceso libre</i>	22	50,0%	155	96,9%	55	34,8%	233	64,1%
<i>Fuentes</i>	23	-	44	-	32	-	76	-
FORMATO								
<i>Tabla</i>	17	38,6%	110	68,8%	62	39,2%	189	52,2%
<i>Documento</i>	7	15,9%	69	43,1%	13	8,2%	89	24,6%
<i>Imagen</i>	3	6,8%	41	25,6%	1	0,6%	45	12,4%
<i>Texto</i>	1	2,3%	28	17,5%	0	0,0%	29	8,0%
<i>Archivo</i>	0	0,0%	17	10,6%	9	5,7%	26	7,2%
<i>Otros</i>	16	36,4%	21	13,1%	73	46,2%	110	30,4%
PERFIL								
<i>General</i>	18	40,9%	55	34,4%	70	44,3%	143	39,5%
<i>Comercial</i>	9	20,5%	18	11,3%	57	36,1%	84	23,2%
<i>Tecnología</i>	3	6,8%	18	11,3%	0	0,0%	21	5,8%
<i>Educación</i>	5	11,4%	6	3,8%	0	0,0%	11	3,0%
<i>Salud</i>	15	34,1%	93	58,1%	59	37,3%	167	46,1%
<i>Clínico</i>	8	18,2%	76	47,5%	11	7,0%	95	26,2%

Respecto al acceso a los conjuntos de datos, en promedio, el

64,1% (233) de los conjuntos de datos tiene acceso libre. Sin embargo, el porcentaje varía considerablemente según las palabras clave utilizadas en las búsquedas, destacándose "*ophthalmology*" con un 96,9%, en contraste con los resultados más bajos de "*eye care*" (34,8%), como se observa en la Figura 4.2-B.

En cuanto al formato, más de la mitad de los datos (52,2%) se presentaron en tablas, mientras que los documentos representaron el 24,6% y las imágenes el 12,4%. Los textos y archivos combinados representaron menos del 15%, mientras que el 30,4% se clasificó como "otros", lo que refleja la diversidad de formatos encontrados, lo cual podría indicar una falta de uniformidad en la categorización o la inclusión de formatos menos convencionales (Figura 4.2-D).

Se identificó un total de 76 fuentes de datos, de las cuales 44 estaban relacionadas con la búsqueda en "*Ophthalmology*" y solo 22 con "*Optometry*" (Figura 4.2-C). Destaca que la mayor fuente identificada fue el sitio [statista.com](https://www.statista.com), una plataforma que proporciona estadísticas y estudios de mercado en diversos sectores, incluyendo salud y tecnología, donde se identificaron 127 conjuntos de datos. El segundo mayor proveedor fue el servicio data.mendeley.com, un repositorio de datos de investigación que facilita el almacenamiento y la publicación de conjuntos de datos científicos. Este sitio contribuyó con 7 y 16 conjuntos de datos para las palabras clave "*Optometry*" y "*Ophthalmology*", respectivamente. Para la palabra clave "*eye care*", el segundo lugar correspondió a la plataforma [figshare.com](https://www.figshare.com), un repositorio digital de acceso abierto que permite compartir y publicar diversos resultados de investigación, que aportó 17 conjuntos de datos.

El predominio del formato de tabla sugiere una estandarización hacia estructuras más útiles para análisis cuantitativos, mientras que la alta proporción de formatos clasificados como "otros" indica que probablemente sea necesaria una mejora en la estandarización de estos datos para facilitar su uso.^{163,164} Asimismo, las marcadas diferencias en el acceso libre encontradas para la búsqueda en Optometría destacan la importancia de promover estrategias que favorezcan el acceso a datos en todas las áreas de las ciencias de la visión. Además se observa que, a pesar de la diversidad de fuentes, existe una evidente ausencia de plataformas consolidadas y dedicadas exclusivamente a las ciencias de la visión. El predominio de Statista como proveedor principal puede atribuirse a su enfoque genérico y a su capacidad para consolidar datos de diversas áreas; no obstante, su contribución a investigaciones clínicas específicas es limitada. Por otro lado, plataformas especializadas como Mendeley y Figshare destacan como repositorios académicos confiables, aunque su menor representación en los hallazgos resalta la necesidad de incrementar la disponibilidad de datos relevantes dedicados a las ciencias de la visión, lo que incrementaría el acceso a recursos que apoyen investigaciones específicas y fomenten el avance en esta área.^{165,166}

Respecto al perfil de los datos, el 46,1% se relacionó con la categoría de salud, mientras que un 26,2% correspondió a datos clínicos. Aunque estos últimos representan una proporción menor, su relevancia puede ser significativa, ya que suelen ser más específicos y directamente aplicables en contextos profesionales. El 39,5% restante abarcó perfiles generales, comerciales, tecnológicos y educativos, lo que muestra un panorama amplio pero heterogéneo en el uso potencial de estos datos (Figura 4.3-A).



Figura 4.3. Perfil de los conjuntos de datos clasificados según el tipo de uso, atención sanitaria y relación ocular. **A:** Tipo de uso de las bases de datos. **B:** Distribución por nivel de atención en salud de los datos clínicos. **C:** Distribución de las 10 primeras áreas de los datos clínicos en ciencias de la visión.

En cuanto a la distribución por nivel de atención sanitaria, la mayoría de los conjuntos de datos categorizados como clínicos están concentrados en el segundo nivel de atención (58%), seguido por el tercer nivel (27%), mientras que solo el 15% de los datos corresponden con el primer nivel de atención (Figura 4.3-B). Estos resultados demuestran una menor representación de bases de datos en niveles de atención básica. Por otro lado, los datos clínicos analizados muestran que la mayor proporción de estas bases está asociada a la retina (19,8%), seguida por exámenes generales (15,6%) y datos relacionados con el polo

anterior (excepto córnea y catarata), que representan el 13,5% del total (Figura 4.3-C). Otros perfiles relevantes incluyen cirugía (11,5%) y córnea (10,4%), mientras que categorías como COVID-19 y catarata constituyen, cada una, cerca del 7% del total. A pesar de la presencia de temas variados, como glaucoma (4,2%) y baja visión (2,1%), se observa que perfiles más específicos, como refracción, campo visual, ambliopía, ojo seco, lentes oftálmicas y otras, tienen una representación mínima, siendo del 1,0% cada uno.

Estos resultados, (detallados en la Tabla 4.3), destacan la predominancia de conjuntos de datos orientados a áreas específicas de alto impacto, como retina y cirugía, lo que refleja el enfoque de las investigaciones en condiciones que requieren intervenciones complejas, así como la subrepresentación de áreas como la refracción o la baja visión que sugiere una brecha en la disponibilidad de datos más amplios o aplicables al nivel de atención primaria visual, en línea con los resultados encontrados en el estudio presentado en el Capítulo 3 de esta Tesis Doctoral.¹⁶²

Tabla 4.3. Perfil de los conjuntos de datos de características clínicas y su relación con el nivel de atención sanitaria. (* excluido córnea y catarata).

Perfiles clínicos	TOTAL		Atención a la salud		
	n	%	1ª	2ª	3ª
<i>Retina</i>	19	19,8%	0	19	0
<i>Exámenes</i>	15	15,6%	2	10	3
<i>*Polo anterior</i>	13	13,5%	0	13	0
<i>Cirugía</i>	11	11,5%	0	0	11
<i>Córnea</i>	10	10,4%	3	7	0
<i>COVID-19</i>	9	9,4%	5	4	0
<i>Catarata</i>	7	7,3%	0	7	0
<i>Lente de contacto</i>	7	7,3%	7	0	0
<i>Signos y síntomas</i>	7	7,3%	7	0	0
<i>Síndromes</i>	6	6,3%	1	3	2
<i>Agudeza visual</i>	5	5,2%	5	0	0
<i>Glaucoma</i>	4	4,2%	0	4	0
<i>Tracto uveal</i>	4	4,2%	0	4	0
<i>Baja visión</i>	2	2,1%	0	2	0
<i>DMAE</i>	2	2,1%	0	2	0
<i>Refracción</i>	1	1,0%	1	0	0
<i>Ambliopía</i>	1	1,0%	1	0	0
<i>Campo visual</i>	1	1,0%	0	1	0
<i>Esclera</i>	1	1,0%	0	1	0
<i>Lente Oftálmica</i>	1	1,0%	1	0	0
<i>Neurológico</i>	1	1,0%	0	0	1
<i>Oculomotor</i>	1	1,0%	1	0	0
<i>Ojo Seco</i>	1	1,0%	1	0	0
<i>Sensibilidad al Contraste</i>	1	1,0%	1	0	0
<i>Tracoma</i>	1	1,0%	0	1	0

4.4. Difusión

Los principales resultados de este trabajo se presentaron en el congreso OPTOM 2022 en formato póster (Figura 4.4).

27º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica – OPTOM 2022. Comunicación Póster: **Disponibilidad y características de conjuntos de datos clínicos para uso en las ciencias de la visión**. Stuermer L, Braga S, Martín R. - al 03 de abril de 2022. (España).




Figura 4.4. Detalle del poster presentado en congreso OPTOM 2022.

Propuesta de plataforma *big data* para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular

*Proposal for a big data platform for
optometry based on a review of
protocols and clinical data
repository models in eye health*



5.1. Introducción

La ciencia de datos ha transformado profundamente el ámbito de la salud, impulsando avances clave en el diagnóstico, la predicción de enfermedades y la personalización de tratamientos.^{167–169} Este progreso también se refleja en el área de la salud visual y ocular (Capítulo 3), donde el uso de datos ha mejorado la precisión y rapidez en los diagnósticos^{55,155}, además de contribuir a la reducción de costos y al acceso más eficiente a los servicios sanitarios.^{153,170}

La digitalización de los datos en salud ha revolucionado la forma en que se realizan investigaciones y se gestionan recursos clínicos, con los registros electrónicos de salud (RES) - en inglés *electronic health records (EHR)* - desempeñando un papel fundamental en este avance.^{16,171} Al organizar los datos, los RES no solo mejoran el acceso a información relevante, sino que también garantizan una gestión eficiente mediante estándares y protocolos que aseguran la interoperabilidad, la seguridad y el uso ético de los datos.¹⁵⁹ En este contexto, sistemas como los Data Warehouses (DW), grandes depósitos de datos diseñados para consolidar información de múltiples fuentes, permiten analizar tendencias y tomar decisiones estratégicas. En el ámbito de la salud, se destacan el Clinical Data Warehouse (CDW) y el Research Data Warehouse (RDW), adaptados específicamente para integrar y analizar datos clínicos y de investigación. Por su parte, los Integrated Data Repositories (IDRs) combinan estas funciones,

integrando datos clínicos, administrativos y de investigación en una plataforma centralizada, lo que facilita tanto la gestión clínica en tiempo real como el desarrollo de investigaciones científicas.¹⁵¹

Por su parte, los repositorios de datos clínicos, como los CDW o IDRs, desempeñan un papel esencial en la consolidación, centralización y acceso a los RES, permitiendo el almacenamiento estructurado y seguro de grandes volúmenes de datos sensibles, así como en la gestión, disponibilidad y uso de estos conjuntos de información.^{154,157,172} Sin embargo, a pesar de la constante producción de datos optométricos a nivel mundial, este área específica parece tener una limitada disponibilidad de repositorios dedicados y una muy baja accesibilidad a datos clínicos (como se señala en el Capítulo 4), lo que dificulta el desarrollo de proyectos de investigación además de restringir el fortalecimiento y desarrollo del conocimiento en atención primaria en salud visual.¹⁶²

Considerando el impacto potencial que el almacenamiento de datos clínicos podría tener en el desarrollo de los cuidados de la visión, y dado el limitado acceso actual a conjuntos de datos clínicos públicos (tal y como se muestra en el Capítulo 4), el objetivo de este capítulo es proponer un modelo de plataforma global de almacenamiento de datos dedicado a la Optometría, basado en el estudio previo de estándares relacionados con los RES y en los modelos actuales de repositorios de salud ocular.



5.2. Material y Método

Se realizaron tres etapas (Figura 5.1) tal y como se describe a continuación:

Etapas 1: Revisión de normas y directrices para RES

Se realizó una búsqueda bibliográfica en PubMed utilizando la siguiente estrategia de búsqueda: *((("big data"[Title/Abstract]) OR ("electronic health records"[Title/Abstract]) OR (EHR[Title/Abstract])) AND ((standards[Title]) OR (protocols[Title]) OR (guidelines[Title]))).*

Se aplicaron filtros específicos para refinar los resultados, incluyendo artículos publicados en los años 2019 a 2023, con acceso gratuito al texto completo. Además, se limitaron los resultados según el tipo de artículo, seleccionando únicamente revisiones y revisiones sistemáticas, publicados en inglés (idioma de inclusión).

Se identificaron 12 publicaciones. Tras un análisis inicial, se excluyeron 5 artículos que no aportaban información relevante al objetivo del trabajo, dejando un total de 7 artículos.^{33,39,173–177} Un análisis cualitativo permitió identificar los estándares y protocolos más relevantes relacionados con los RES. Estos hallazgos se clasificaron según su tipo y función, destacando los puntos clave más significativos.




Figura 5.1. Resumen general de las tres etapas realizadas. RES= registros electrónicos de salud

Etapas 2: Identificación de repositorios en ciencias de la visión

Se realizó una búsqueda en Google (www.google.com), empleando diferentes combinaciones de palabras clave relacionadas con el almacenamiento electrónico en salud ocular, combinando términos como 'repository', 'base', 'data' o 'set' con 'optometry', 'ophthalmology', 'vision' y 'eye'.

Los resultados fueron analizados cualitativamente para identificar repositorios de datos dedicados a la visión. Los hallazgos se clasificaron según su operador, alcance y tipo de datos almacenados. Además, se investigaron publicaciones científicas en PubMed utilizando como palabra clave el nombre o sigla de los repositorios identificados, sin filtros, evaluando su relevancia y el número de estudios que los mencionaban.

Etapas 3: Propuesta de una plataforma para datos de salud visual

En la última etapa, los hallazgos obtenidos en las fases anteriores se integraron para diseñar un modelo de plataforma de almacenamiento de datos en salud visual. Esta propuesta se desarrolló a partir de la síntesis de los estándares, referencias y características identificadas tanto en el manejo de RES como en los modelos preexistentes de plataformas encontradas. El modelo fue diseñado en forma de un mapa conceptual,^{178,179} es decir, con diagramas visuales que ilustran las relaciones entre diferentes conceptos o ideas, presentando así la estructura general y las funcionalidades fundamentales propuestas para esta plataforma.



5.3. Resultados y discusión

Etapas 1: Revisión de normas y directrices para RES

La revisión identificó una amplia variedad de estándares aplicados al manejo de RES, destacando un total de 24 elementos, 17 protocolos, una legislación y 6 políticas de seguridad (Tabla 5.1 Inferior), que fueron agrupados en cuatro categorías principales (Tabla 5.1 Superior) denominados: interoperabilidad (11; 45,8%), accesibilidad (7; 29,1%), seguridad (13; 54,1%) y privacidad (3; 12,5%). Estos resultados muestran un equilibrio entre la necesidad de garantizar una comunicación y flujo de datos eficiente, principalmente a través de protocolos informáticos técnicos, y la importancia de proteger adecuadamente la información en conformidad con las normativas vigentes. Es decir, existe una clara preocupación por los aspectos éticos vinculados a la manipulación de datos de terceros.^{180,181}

En las categorías de interoperabilidad y accesibilidad se incluyen elementos que optimizan el flujo de información. Mientras la interoperabilidad garantiza el intercambio y uso eficiente de los datos entre diferentes plataformas, la accesibilidad se centra en que la información sea fácilmente comprendida y utilizada por los usuarios. Las categorías de seguridad y privacidad, aunque complementarias, tienen enfoques distintos, ya que la seguridad se orienta a proteger los datos, con énfasis en su integridad y resguardo físico, mientras que la

privacidad aborda la protección de la información personal y el cumplimiento ético. Además, es importante destacar que los protocolos identificados podían estar asociados a más de una categoría, reflejando su aplicabilidad transversal en los sistemas de salud.

En la categoría de interoperabilidad, destacan *HL7* (Health Level 7), un estándar ampliamente utilizado para el intercambio de información clínica, y *FHIR* (Fast Healthcare Interoperability Resources), una evolución de HL7 diseñada para facilitar la interoperabilidad mediante el uso de APIs (Application Programming Interface), permitiendo una integración más eficiente entre sistemas. En accesibilidad, los estándares *DICOM* (Digital Imaging and Communications in Medicine) y *PACS* (Picture Archiving and Communication Systems) optimizan la visualización, el almacenamiento y el intercambio de imágenes médicas, mientras que *API* desempeña un papel clave en la integración de diferentes aplicaciones.

En seguridad, los protocolos *SSL/TLS* (Secure Sockets Layer/Transport Layer Security) garantizan la encriptación de la información durante su transmisión, protegiéndola frente a accesos no autorizados o interceptaciones, mientras que la criptografía refuerza la confidencialidad de los datos en almacenamiento. Además, el control de acceso restringe el uso de la información únicamente a usuarios autorizados. En cuanto a privacidad, las políticas de anonimización protegen la identidad de los pacientes en bases de datos de salud, el consentimiento garantiza que el uso de la información esté previamente autorizado, y la legislación, con normativas como el GDPR en Europa, establece directrices para la protección de datos sensibles.

Tabla 5.1. Resumen de protocolos y políticas frecuentes para RES. **Parte Superior:** Descripción de cada categoría asociada con los hallazgos; **Parte Inferior:** Elementos identificados con su descripción y categorización según su función.

Categoría	Descripción
interoperabilidad	Facilita el intercambio eficiente y la estandarización de conceptos clínicos en sistemas sanitarios.
accesibilidad	Promueve el acceso y uso eficiente de datos para mejorar la calidad de la atención.
seguridad	Garantiza la protección, confidencialidad e integridad de la información de salud con medidas de seguridad.
privacidad	Respetar los derechos del paciente mediante consentimiento, anonimización y cumplimiento de normas de privacidad.

Protocolos y políticas	Categoría				Descripción
	i	a	s	p	
HL7					Intercambio de mensajes entre sistemas de salud
CDA					Estructuración de documentos clínicos interoperables
SNOMED CT					Nomenclatura internacional de conceptos clínicos
LOINC					Identificación de pruebas y observaciones clínicas
CPT					Codificación de procedimientos médicos
FHIR					Estándar de interoperabilidad con soporte para APIs
IHE					Perfiles para mejorar el intercambio de información
ICD-10					Clasificación Internacional de Enfermedades (CIE)
DICOM					Estándar para intercambio y visualización de imágenes
PACS					Comunicación y archivo de imágenes médicas
API					Interfaz de programación para integración de aplicaciones
WAI-ARIA					Especificación para accesibilidad de aplicaciones web
CDS Hooks					Especificación para soporte a decisiones clínicas
HIPAA					Protección de información de salud en EEUU
NIST					Directrices y estándares de seguridad
SSL/TLS					Protocolos de encriptación para datos
<u>Criptografía</u>					Técnicas para proteger la confidencialidad
<u>Backup</u>					Políticas de copia de seguridad y recuperación
<u>Control de acceso</u>					Restricción de acceso a usuarios autorizados
<u>Firewalls</u>					Protección de redes contra accesos no autorizados
LOG					Registro de actividades para detectar violaciones
Legislación (GDPR - Europa)					Ley General de Protección de Datos (LGPD)
<u>Anonimización</u>					Protección de la privacidad en datos de salud
<u>Consentimiento</u>					Consentimiento de pacientes para uso de datos

La diversidad de protocolos identificados refleja el compromiso global

con la interoperabilidad y la protección de los datos de salud, aspectos fundamentales para el desarrollo de sistemas eficaces y seguros no solo en el ámbito de la salud visual,¹⁸² sino también relacionados con la salud pública^{42,45} que precisa estándares para la convergencia de datos y diagnósticos de condiciones sistémicas. Aunque los datos clínicos sintéticos pueden generarse actualmente a partir de datos reales, aún existen preocupaciones relacionadas con cuestiones éticas y de privacidad, particularmente en lo referente a la seguridad de la información, desde el almacenamiento de parámetros biométricos sensibles hasta su posible uso futuro. Incluso cuando el uso de estos datos se oriente a fines de salud pública, se trata de información sujeta a consentimiento privado y requiere la autorización explícita del paciente⁴⁰, lo que convierte este aspecto en un punto crítico para los CDW.^{33,39,161,173–177}

Etapas 2: Identificación de modelos de repositorios en CV

Se identificaron 13 referencias relacionadas con el almacenamiento de datos dedicados exclusivamente a la salud ocular, pero solo 5 de ellas contaban con publicaciones científicas asociadas (Tabla 5.2). La plataforma más destacada fue IRIS (Intelligent Research in Sight), administrada por la *American Academy of Ophthalmology* (AAO) en los Estados Unidos, que cuenta con el mayor número de publicaciones en PubMed (un total de 82). Esta plataforma se basa en datos clínicos derivados de RES, representando el 46,3% de todos los hallazgos que relacionan estudios con los nombres de las plataformas.

La plataforma FRB! (Fight Retinal Blindness), vinculada a la University of Sydney, tiene un alcance más global y constituye uno de los principales repositorios internacionales de datos clínicos en

oftalmología, con 50 publicaciones relacionadas, lo que la posiciona como la segunda fuente más representativa entre los hallazgos analizados (28,3%). Le sigue el sistema INSIGHT (Health Data Research Hub), un hub de datos enfocado en la investigación, destaca como uno de los principales referentes en el Reino Unido. Liderado por la University of Birmingham y el Moorfields Eye Hospital, cuenta con 37 publicaciones indexadas en PubMed, lo que representa el 20,9% del total de hallazgos relacionados. Junto con las plataformas IRIS y FRB! concentran más del 95% de la representatividad de los estudios encontrados.

Otras dos plataformas, AVEHSS y GVD, también registraron citas científicas, aunque en números menos representativos (6 y 2, respectivamente). Por otro lado, todas las demás referencias encontradas no tenían publicaciones asociadas o no estaban activas. Por ejemplo, AOA MORE (*Measures and Outcomes Registry for Eyecare*), vinculada a la American Optometric Association (AOA), aparentemente se reporta como inactiva o no cuenta con información clara y actualizada sobre su sistema. Algunas plataformas sugieren la existencia de datos con contenido específico, pero no se encontró información sobre la cobertura o la región que abarcan los datos almacenados. Entre estas, para SMEYEDAT y SOURCE, no se identificaron los proveedores u organizaciones líderes, mientras que E3 y AEEC están gestionadas por un consorcio y se centran en datos de salud ocular en Europa y Asia, respectivamente.

Por último, una iniciativa de *Optometry Australia* (OA), llamada '*Optometry 2040*', se inició en 2018 con el objetivo de identificar escenarios plausibles para la optometría y la salud ocular

comunitaria.¹⁸³ Dentro de este marco, se contempla la creación de sistemas para la recopilación y gestión centralizada de datos clínicos. Sin embargo, dado que no se muestran detalles específicos sobre esta descripción, se clasificó este hallazgo como un proyecto en desarrollo. Por otro lado, la iniciativa '*UK Eye Care Data Hub*' fue lanzada públicamente en enero de 2025, como parte de un consorcio de entidades liderado por The College of Optometrists, que abarca el Reino Unido e Irlanda y tiene como propósito analizar la plantilla (workforce) actual de profesionales del cuidado de la visión así como la prevalencia o incidencia de enfermedades oculares, para identificar tendencias futuras que ayuden a los responsables de diseñar los servicios de atención visual en Reino Unido a identificar las necesidades futuras de cuidados de salud visual de la población con el fin de optimizar la plantilla de estos profesionales.¹⁸⁴

La identificación de estos repositorios clínicos reveló que, a pesar de la existencia de algunas plataformas dedicadas a la salud ocular, solo un número limitado de ellos cuenta con reconocimiento científico y publicaciones asociadas. Entre ellas, la plataforma IRIS,^{154,185} gestionada por la *American Academy of Ophthalmology*, destaca como la más utilizada, representando el 43% de las publicaciones encontradas, aunque con un alcance limitado a los EE. UU. Por otro lado, la plataforma FRB!, con presencia en diversos países, constituye un ejemplo igualmente relevante al posicionarse como un repositorio internacional de datos en oftalmología, con casi un tercio (28,3 %) de los estudios encontrados. Su enfoque, no obstante, se centra en enfermedades retinianas.¹⁸⁶

Tabla 5.2. Resumen de las plataformas de repositorios de datos dedicados a la salud ocular encontradas. RES= registros electrónicos de salud.

Acrónimo	Nombre	Proveedor	Alcance	Pubmed	Observaciones
IRIS	Intelligent research in sight	American Academy of Ophthalmology (AAO)	EE. UU.	82	Conocimiento científico basado en evidencia derivado de registros de datos clínicos
FRB!	Fight Retinal Blindness	Foundation of the Save Sight Registries Save Sight Institute - The University of Sydney	Global (Europa, Oriente Medio y Asia)	50	Datos longitudinales - degeneración macular relacionada con la edad
INSIGHT	Health Data Research Hub	University of Birmingham Moorfields Eye Hospital	Reino Unido	37	-
VEHSS	Vision and Eye Health Surveillance System	Centers for Disease Control and Prevention (CDC)	EE. UU.	6	Incluye 11 bases (entre ellas 'IRIS')
GVD	Global vision database	Visual Loss Expert Group (VLEG)	Global	2	-
AOA More	Measures and outcomes registry for eyecare	American Optometric Association (AOA)	EE. UU.	0	Inactivo
SMEYEDAT	Smart Eye Database	-	-	0	RES e imágenes diagnósticas
SOURCE	Sight Outcomes Research Collaborative	-	-	0	Identificación de enfermedades oculares con datos de RES
E3	European Eye Epidemiology	consorcio	-	0	-
AEEC	Asian Eye Epidemiology	consorcio	-	0	-
EUREQUO	European Registry of Quality Outcomes for Cataract and Refractive Surgery	European Society of Cataract and Refractive Surgeons (ESCRS)	-	0	Cirugía de cataratas y refractiva
-	Optometry 2040	Optometry Australia (OA)	Australia	0	Proyecto (Creación de base de datos, parte del Optometría 2040)
-	UK Eye Care Data Hub	consorcio con el The College of Optometrists (líder)	Reino Unido e Irlanda	0	Lanzada (enero/24) para modelar tendencias y monitorear enfermedades oculares

Si bien se ha confirmado la escasez de CDW dirigidos a la atención visual primaria, los hallazgos sugieren una tendencia creciente para abordar esta carencia. Esto se refleja tanto en plataformas aparentemente inactivas en la actualidad, como AOA More¹⁸⁷ (desarrollada por la American Academy of Optometry), como en iniciativas activas, entre ellas el proyecto Optometría 2040 de Optometry Australia¹⁸⁸ y, en especial, el reciente lanzamiento del UK Eye Care Data Hub,¹⁸⁴ impulsado por el Colegio de Optometristas del Reino Unido. Estos esfuerzos institucionales parecen orientar acciones hacia un modelo estructurado de gestión y aprovechamiento de datos en salud visual, lo que, aunque aún requerirá tiempo para su consolidación, representa un avance positivo en especial para el desarrollo y avance de la investigación en atención visual primaria.¹⁸⁹

Etapas 3: Propuesta de una plataforma para datos de salud visual

Compilando el conocimiento obtenido a partir de los resultados de las etapas anteriores, se propone la creación de una plataforma de registros clínicos electrónicos para la salud visual, denominada DAVIH (Data Vision Health). Esta plataforma sería administrada por un consorcio técnico compuesto por asociaciones, universidades y expertos del área, representando diferentes países dentro de su alcance. Debido a la naturaleza global de la propuesta, los mapas conceptuales están rotulados en inglés, idioma elegido para facilitar su comprensión a nivel internacional. Los detalles de la plataforma se presentan a continuación en seis mapas conceptuales, comenzando por el mapa GENERAL (Figura 5.2), seguido de las secciones específicas (IN, OUT, STORAGE, DATA y PROTOCOLS), que en su conjunto describen la estructura y el funcionamiento del sistema.




Figura 5.2. Representación esquemática general de la plataforma *DAVIH* (*Data Vision Health*) que presenta la estructura y los flujos de información de un sistema integral para el almacenamiento y gestión de datos en salud visual, integrándose con mapas identificados como 'IN', 'OUT', 'DATA', 'PROTOCOLS' y 'STORAGE'. APP/EHR = aplicaciones digitales diversas con registros electrónicos de salud.

General - mapa esquemático

En la sección de entrada (*'INPUT'*), se ilustra cómo se pueden recolectar los datos desde diversas fuentes, incluyendo profesionales de ópticas, clínicas y/u hospitales, mediante aplicaciones aprobadas y sistemas digitales con uso de RES. Esta información atraviesa capas de comunicación y seguridad, donde protocolos como FHIR, DICOM y API, junto con formatos JSON, garantizan la interoperabilidad y la integridad de los datos. Los detalles específicos de esta sección pueden consultarse en el mapa de la Figura 5.3 - IN.

En la plataforma DAVIH - Data Vision Health, los datos son cifrados para garantizar su seguridad y posteriormente almacenados de forma remota en la nube. Esta sección también destaca la estructura organizativa de la plataforma, gestionada por un consorcio administrativo responsable de la supervisión, el control de acceso y la implementación de políticas de seguridad. Este enfoque colaborativo asegura la integridad de los datos y su disponibilidad para fines científicos y clínicos, alineándose con los objetivos de la plataforma, los cuales se detallan en la Figura 5.4 - STORAGE.

En la sección de salida (*'OUTPUT'*), la plataforma facilita el acceso a los datos a través de interfaces web, promoviendo la colaboración entre instituciones y sociedades científicas para apoyar investigaciones epidemiológicas y análisis en ciencia de datos, tal como se describe en la Figura 5.3 - OUT. Además, las referencias sobre los protocolos utilizados y el formato de los datos están representadas, respectivamente, en los mapas de la Figura 5.4 - DATA y la Figura 5.4 - PROTOCOLS.

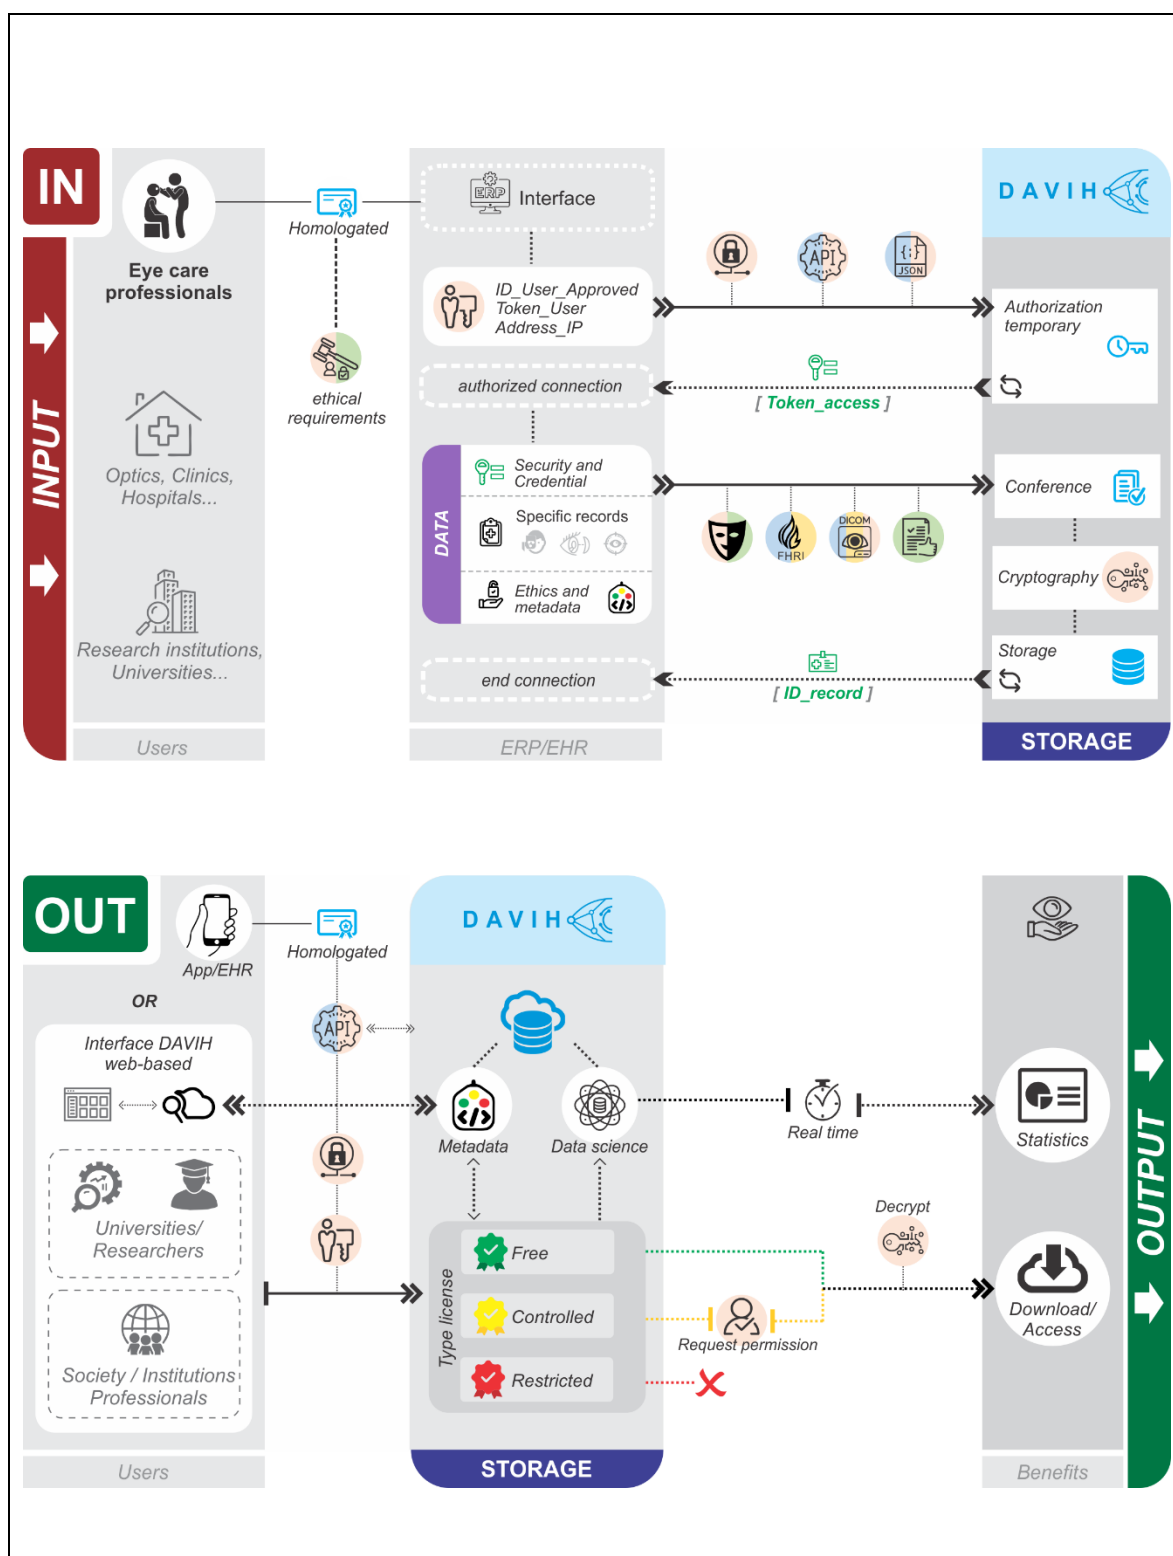


Figura 5.3. Mapas conceptuales de entrada y salida de datos en la plataforma DAVIH. **IN** (superior): muestra el flujo de comunicación para el envío de datos. **OUT** (inferior): representa el resumen del proceso de acceso a los datos almacenados.

Entrada y Salida - mapa esquemático

El mapa 'IN' presenta las etapas propuestas para el envío de datos a la plataforma (entradas), comenzando con la homologación de ERP, en cumplimiento de los requisitos legales. Se establece una secuencia de comunicaciones internas con la plataforma para garantizar el control de acceso y la seguridad, culminando en la transmisión de los datos. Para ello, se emplean como estándares los protocolos FHIR y DICOM para datos clínicos, así como metadatos, que incluyen información que facilita la interpretación y búsqueda, además de aplicar políticas de anonimización y consentimiento. Una vez completada esta etapa, los datos son cifrados y almacenados, y si el proceso se realiza correctamente, se genera un identificador que es devuelto al ERP de origen, permitiendo su control futuro para edición, eliminación o adición de datos de seguimiento, finalizando el de envío de datos.

El mapa 'OUT' propone una interfaz web propia de DAVIH para la consulta de datos almacenados, así como la posibilidad de integración directa mediante API con los ERP previamente homologados. Tras superar las capas de seguridad, incluyendo TLS y control de acceso, los datos pueden ser accedidos según el nivel de autorización definido en el almacenamiento, con opciones de acceso libre, acceso mediante autorización o datos restringidos sin acceso público (solo para análisis internos). Todos los datos pueden ser utilizados para análisis, tanto bajo la supervisión y control de la gestión administrativa de DAVIH, como para la generación de estadísticas y predicciones relacionadas con la salud ocular y visual, proporcionando beneficios en diversas áreas, desde la investigación hasta el fortalecimiento de instituciones y servicios de salud pública.

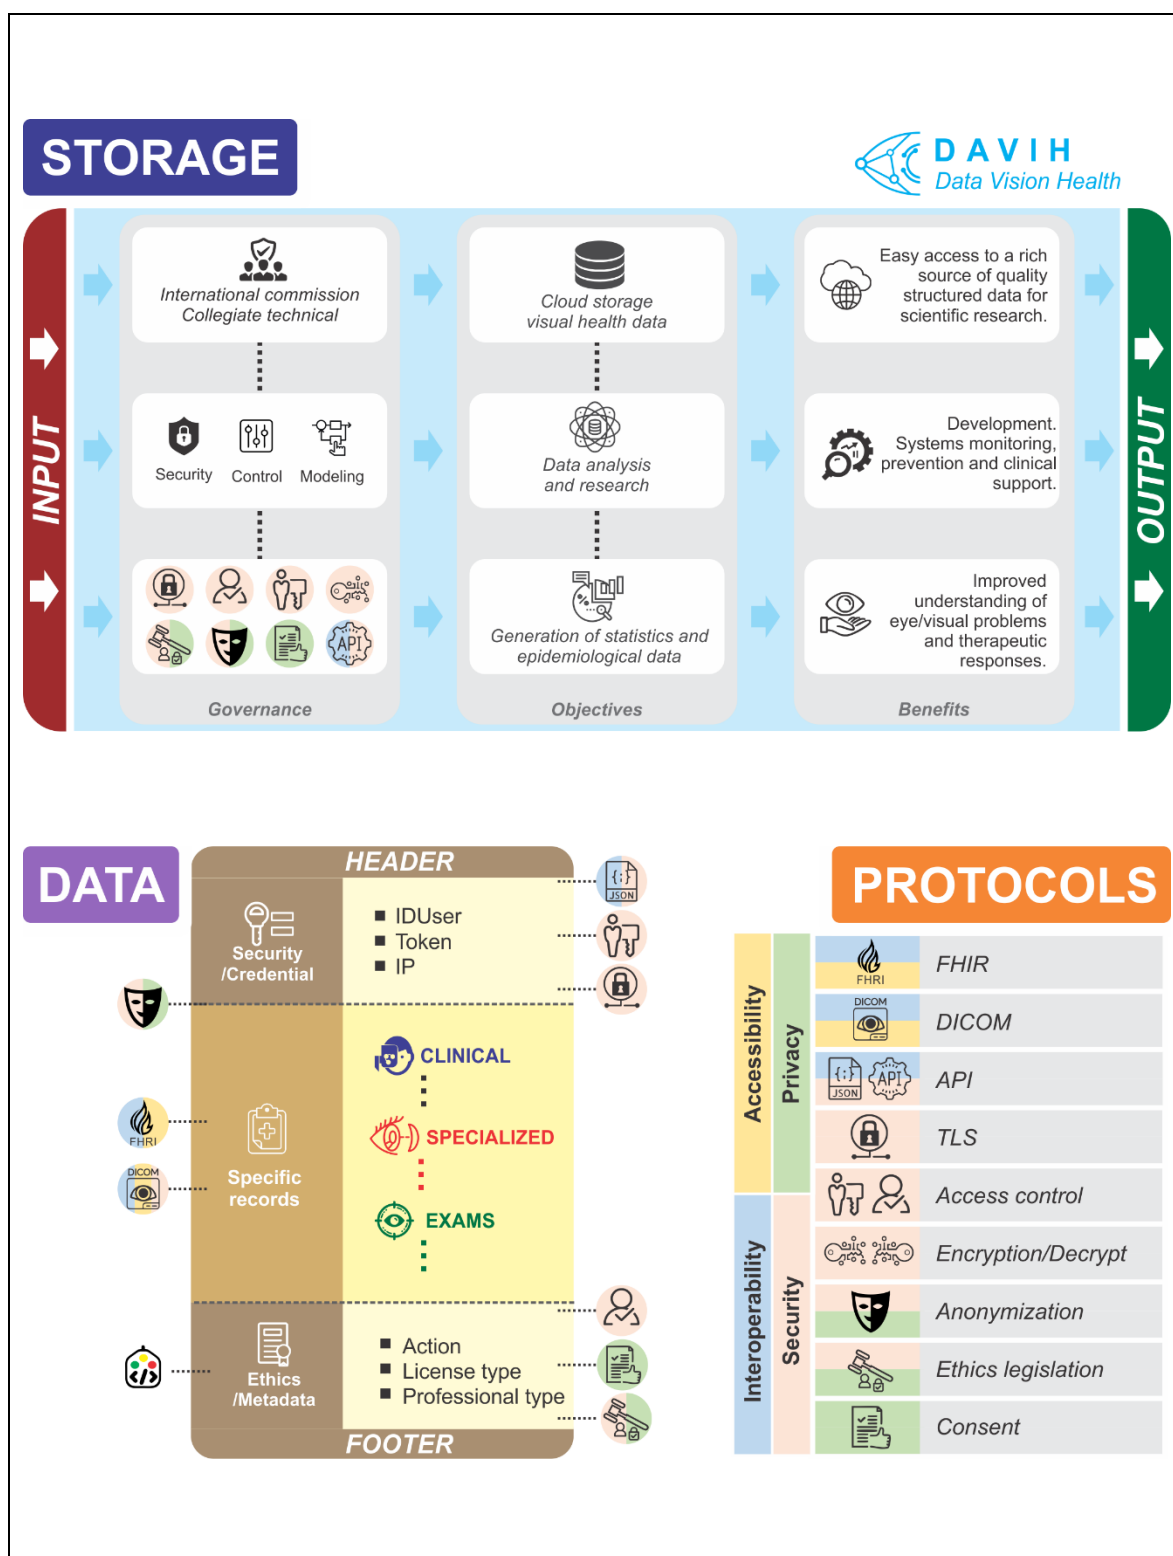


Figura 5.4. Mapas conceptuales de la estructura de almacenamiento, organización de los datos y protocolos. **STORAGE** (superior): muestra la síntesis general de la plataforma DAVIH. **DATA** (inferior izquierdo): define los formatos estándar de los registros de datos almacenados. **PROTOCOLS** (inferior derecho): presenta los estándares de interoperabilidad, accesibilidad, seguridad y privacidad asociados.

Almacenamiento, datos y protocolos - mapa esquemático

El mapa '*STORAGE*' sintetiza la estructura de almacenamiento de la plataforma DAVIH, abarcando desde su gobernanza, pasando por la aplicación de los protocolos establecidos, hasta su almacenamiento en la nube, lo que permite la generación de estadísticas epidemiológicas. Esta arquitectura está diseñada para facilitar el acceso a una fuente de datos estructurados de alta calidad para la investigación científica, promoviendo el desarrollo de sistemas de monitoreo, prevención y apoyo clínico, además de mejorar la comprensión de los problemas oculares y sus respuestas terapéuticas.

El mapa '*DATA*' detalla la estructura de los registros almacenados, organizándolos en datos clínicos, especializados y de exámenes, garantizando que la información se almacene de manera estructurada y coherente. Además, en los metadatos se especifican las licencias de uso y el tipo de profesional autorizado para acceder a cada categoría de datos. Por último, el mapa '*PROTOCOLS*' describe los estándares utilizados en la plataforma para garantizar la interoperabilidad, accesibilidad, seguridad y privacidad de los datos, asegurando un flujo de información confiable y alineado con las normativas vigentes.

La propuesta de la plataforma DAVIH es una respuesta a la brecha que limita la disponibilidad de datos clínicos reales (*Real-World Data - RWD*), organizados y estructurados para su uso en investigación y en análisis epidemiológico, lo que dificulta el desarrollo de modelos predictivos y estrategias de prevención en salud visual.^{190–192} El modelo propuesto tiene un enfoque robusto que incorpora capas de seguridad avanzadas y mecanismos éticos, aspectos clave en los sistemas DW, especialmente en el manejo de datos clínicos.¹⁹³ Además, busca facilitar

la interoperabilidad, adoptando protocolos de referencia en el intercambio de datos en salud y promoviendo su integración con sistemas de salud ya existentes.^{33,194,195} Asimismo, su estructura basada en licencias de acceso, permite definir diferentes niveles de permiso para investigadores, profesionales de la salud e instituciones, garantizando la conformidad con regulaciones como el GDPR.¹⁹⁶

Uno de los principales desafíos para la implementación de DAVIH radica en su adopción y compatibilidad con sistemas existentes, ya que la integración de nuevas plataformas suele requerir adaptaciones en infraestructura y protocolos locales. Para abordar esta cuestión, la propuesta contempla la homologación de ERP específicos, a ejemplo de algunos modelos identificados de DW.^{154,187} Esto garantizaría que los sistemas utilizados en clínicas, hospitales y centros de investigación sean compatibles con la plataforma y cumplan con los requisitos técnicos y de seguridad establecidos. No obstante, la viabilidad de su implementación dependerá también de la aceptación por parte de los profesionales de la salud visual, pudiendo existir barreras relacionadas con la capacitación tecnológica o la gestión de datos digitales, entre otros factores.¹⁹⁷ A nivel regulatorio, la variabilidad de normativas sobre datos de salud en diferentes países podría representar un obstáculo adicional para su expansión, lo que destaca la importancia del papel de la gobernanza del consorcio propuesto. Este consorcio desempeñaría un papel clave en la coordinación de su implementación, facilitando la adaptación de los sistemas, promoviendo la capacitación de los usuarios y asegurando el cumplimiento de las normativas, además de la implementación y actualización de las políticas internas y de control.⁴⁶

A pesar de los desafíos, DAVIH tiene el potencial de generar un impacto significativo en diferentes ámbitos de la sociedad, desde el apoyo a la investigación hasta la formulación de políticas de salud.¹⁹⁸ Su implementación no solo serviría como un modelo de referencia en el almacenamiento de datos en salud visual, sino que, al proporcionar un repositorio estructurado de datos clínicos, podría estimular el desarrollo de soluciones innovadoras para la toma de decisiones en salud visual.¹⁹⁰ Un ejemplo podría ser el uso de inteligencia artificial, que permitiría la automatización y optimización de diagnósticos.^{54,55,152,155} Además, facilitaría la realización de estudios epidemiológicos a gran escala a través de la aplicación de ciencia de datos, permitiendo la generación de estadísticas en tiempo real basadas en información actualizada,¹⁹⁹ como ocurrió durante la pandemia de la COVID-19, donde los datos, cuando estaban disponibles, generaban informes transparentes de fácil acceso y análisis para los gestores de salud.^{154,187,200}

Para avanzar en esta dirección, los próximos pasos deberían incluir pruebas piloto en entornos clínicos y académicos, así como colaboraciones estratégicas con entidades reguladoras y sociedades científicas. Estas acciones permitirían validar la viabilidad técnica de la plataforma, garantizar su adopción gradual y fortalecer su sostenibilidad a largo plazo.^{45,201} No obstante, el primer paso clave será la organización institucional del consorcio y la definición de todos los aspectos relacionados con la gobernanza del proyecto, para luego avanzar en los procedimientos de implementación, asegurando siempre un equilibrio entre accesibilidad y máxima seguridad, de modo que en el futuro DAVIH pueda convertirse en una realidad y la información esté más fácilmente disponible para beneficiar la salud visual y ocular.

5.4. Difusión

Resultados del estudio se presentaron en el congreso OPTOM 2024 en formato póster (Figura 5.5).

28º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica – OPTOM 2024. Comunicación Póster: **Propuesta de plataforma big data para optometría basada en revisión de protocolos y modelos de repositorio de datos clínicos en salud ocular.** Stuermer L, Braga S, Martín R. - al 14 de abril de 2022. (España).

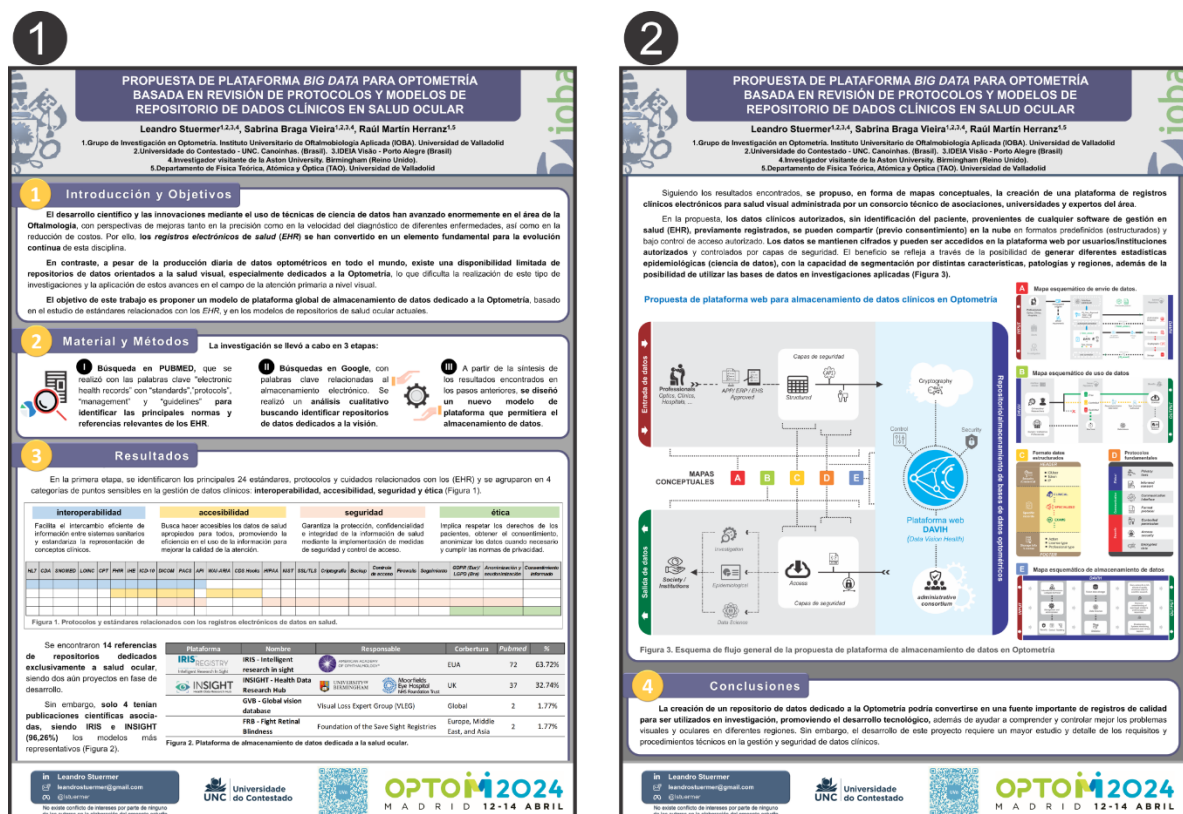


Figura 5.5. Detalle del poster presentado en congreso 'OPTOM 2024'.

Capítulo
Chapter

6

Desarrollo de modelos de inteligencia artificial en atención visual primaria

*Development of artificial
intelligence models in primary visual
care*



6.1. Introducción

La inteligencia artificial (IA) se define como el intento de imitar el pensamiento humano de manera no previamente programada, mediante la manipulación de datos a través de diversos algoritmos de *machine learning* (ML), *deep learning* (DL) y una variedad de redes neuronales (NN).²⁰² Como se analizó en el capítulo 3, en los campos de la Optometría y la Oftalmología, el interés en la IA ha crecido significativamente, ya que esta tecnología tiene el potencial de optimizar el diagnóstico, la terapéutica, el manejo y el cuidado de pacientes con diversas afecciones oculares.²⁰³ Destacan sus aplicaciones en la evaluación de patologías oculares del segmento posterior, como la retinopatía diabética, la degeneración macular relacionada con la edad, el glaucoma, la retinopatía del prematuro²⁰⁴ o la evaluación del agujero macular.²⁰⁵

Además, la IA también se ha aplicado para el análisis de diferentes anomalías del polo anterior,²⁰⁶ como el queratocono, la queratitis infecciosa, las cataratas, la evaluación de la topografía corneal y también en procedimientos quirúrgicos entre los que destacan el trasplante de córnea o la cirugía refractiva.²⁰⁷ Igualmente se ha aplicado para predecir la refracción tras cirugía de cataratas,^{208,209} así como para mejorar el diagnóstico y tratamiento de las afecciones que afectan al desarrollo visual de pacientes pediátricos, en condiciones como la ambliopía, trastornos de la visión binocular y estrabismo entre otros.²⁰⁴

No obstante, el uso de la IA en la práctica clínica sigue siendo limitado debido a factores como la disponibilidad y la heterogeneidad de las técnicas de imagen utilizadas. Estas incluyen la fotografía de fondo de ojo (retinografía), la tomografía de coherencia óptica (OCT), la topografía y tomografía corneal, e incluso la fotografía con lámpara de hendidura.²¹⁰ Esta diversidad ha generado una brecha en la aplicación de modelos de IA basados en hallazgos clínicos, particularmente para su uso o aplicación en atención visual primaria (AVP), según lo evidenciado en los capítulos 3 y 4.

Por este motivo, es necesario generar modelos de IA, entrenados con datos clínicos, para brindar apoyo en el proceso de toma de decisiones, tanto a nivel preclínico como en consultas de AVP ayudando a los profesionales del cuidado ocular y también para mejorar los programas educativos destinados a la formación de profesionales de la salud en general o del cuidado de la visión en particular.



6.2. Material y Método

El estudio se estructura en dos bloques principales. El bloque “*Estructuración de la base de datos*”, que incluye las etapas iniciales de *recolección y modelado*, destinadas a organizar y consolidar la estructura de datos que servirán como base para las fases siguientes; y el bloque “*Ciclo de desarrollo de IA*”, que comprende las etapas iterativas de *preprocesamiento, entrenamiento y validación*, enfocadas en la construcción, ajuste y evaluación de los modelos de IA. Cada una de las subetapas de ambos bloques se describe detalladamente a continuación. Los modelos generados en este estudio se integran en el asistente virtual, cuya implementación se presenta en el Capítulo 7.

Estructuración de la base de datos

Recolección de datos: Se han recopilado datos anonimizados correspondientes a 1125 exámenes optométricos (2250 ojos), realizados entre 2012 y 2021 en la Clínica de Salud Visual de la Universidade do Contestado (Brasil). La muestra incluyó a 708 mujeres (63%) y 417 hombres (37%) con una edad media de 35 ± 20 años. Solo se consideraron historias completas que contenían los diagnósticos y manejos bien identificados. Dado el carácter universitario del centro, solo se incluyeron datos registrados por los profesores supervisores. El estudio cumplió con la Declaración de Helsinki y fue aprobado por el comité de ética de la Universidade do Contestato (*Anexo A*).

Los datos se recopilaron manualmente a partir de las fichas clínicas físicas en papel, las cuales fueron transcritas a hojas de cálculo electrónicas con un formato idéntico al original, utilizando Microsoft Excel 365. Las fichas clínicas se seleccionaron de forma aleatoria para garantizar la mejor representatividad posible de los datos a largo de los años incluidos en el trabajo.

Modelado de los datos: Se utilizaron los programas Excel y Access 365 (Microsoft Corporation, EE.UU., microsoft.com/microsoft-365/) y Orange Data Mining 3.32.0 (University of Ljubljana, Eslovenia, orange.biolab.si/) para el ajuste y depuración de los datos, incluyendo la verificación y corrección de valores inconsistentes y errores tipográficos para garantizar la integridad de la base de datos. Además, como parte del proceso de estandarización de formatos y categorías, se seleccionaron los campos con información consistente y, en el caso de los datos descriptivos, se realizó su transformación a un formato adecuado para el análisis. En particular, algunas categorías fueron segmentadas y convertidas en variables binarias (sí = 1; no = 0), asegurando una representación estructurada de la información.

Los datos fueron organizados en los siguientes grupos específicos: exámenes preliminares (datos generales, agudeza visual (AV) y anamnesis), historia clínica (antecedentes familiares oculares y sistémicos, así como antecedentes oculares personales), pruebas oculomotoras, exploraciones oculares (oftalmoscopia y biomicroscopia), pruebas refractivas (queratometría, retinoscopia y refracción subjetiva) y finalmente la decisión clínica (clasificación del caso, diagnóstico y manejo).

En esta etapa, los datos se organizaron con un enfoque orientado al desarrollo de tres modelos predefinidos: el Modelo 1 (M1) fue diseñado para predecir la clasificación más probable del caso; el Modelo 2 (M2), centrado en la predicción del segmento ocular en el que se encuentren las patologías oculares; y finalmente el Modelo 3 (M3), destinado a identificar disfunciones en la visión binocular (VB). La información de las características planteadas para cada modelo se resume en la Tabla 6.1.

Tabla 6.1. Resumen de las características planteadas para desarrollar los modelos.

Modelos planteados	Modelo 1 (M1)	Modelo 2 (M2)	Modelo 3 (M3)
Objetivo	¿Clasificación del caso?	¿Localización del posible problema ocular patológico?	¿Disfunción de vergencia o acomodación?
Entradas (<i>variables predictoras del grupo</i>)	EXÁMENES PRELIMINARES HISTORIA	EXÁMENES PRELIMINARES HISTORIA PRUEBAS OCULARES	EXÁMENES PRELIMINARES PRUEBAS OCULOMOTORAS
Resultado (<i>Variable objetivo</i>)	Gestión clínica	Trastorno del segmento ocular	Disfunción de la visión binocular
Clases de salida (<i>Valores posibles</i>)	Ninguno Oculomotor Patología ocular Refractivo Oculomotora y patología Refracción y oculomotora Refracción y patología Refracción, oculomotora y patología	Ninguno Polo anterior Polo posterior Polo anterior y posterior	Ninguno Disfunción acomodativa Disfunción de la vergencia fusional Disfunción acomodativa y de vergencia

Ciclo de desarrollo de IA

Esta etapa consistió en procesar y probar diferentes algoritmos de inteligencia artificial para cada problema o predicción definida, con el objetivo de generar el modelo óptimo para su integración en el asistente virtual. Se utilizó Python (3.9.7) (Python Software Foundation, EE.UU., python.org) junto con las bibliotecas Pandas (1.5.3) (Pandas Development Team, EE.UU., pandas.pydata.org/), NumPy (1.26.4) (NumPy Developers, EE.UU., numpy.org/) y Scikit-Learn (1.3.0) (Scikit-learn Developers, France, scikit-learn.org/).

El proceso se estructuró en etapas secuenciales que se describen a continuación.

Preprocesamiento: Con el objetivo de garantizar la calidad de los datos específicamente para cada modelo en desarrollo se seleccionaron las variables significativas, se excluyeron del entrenamiento los datos perdidos y atípicos y se realizó el tratamiento de variables categóricas mediante la técnica de codificación *one-hot encoding*,²¹¹ que convierte valores categóricos en una nueva columna con valores binarios (0 ó 1).

Para mitigar la sensibilidad de los algoritmos de aprendizaje automático a las variaciones numéricas y al desequilibrio de la muestra, se generaron cuatro versiones del conjunto de la base de datos: datos originales desbalanceados (Od), originales balanceados (Ob), datos normalizados desbalanceados (Nd) y normalizados balanceados (Nb). El balanceo se realizó mediante la técnica de *Synthetic Minority Oversampling Technique* (SMOTE), que crea ejemplos sintéticos para las clases minoritarias, equilibrando la distribución de los datos.²¹² Por otro lado, se realizó la normalización de los datos utilizando el método

Min-Max scaling, ajustando los valores numéricos a una escala común entre 0 y 1.²¹³

Analizar estas diferentes versiones de los datos es un paso esencial ya que los algoritmos de aprendizaje automático son sensibles tanto a la distribución como a la escala de los datos. Estas variaciones permitieron identificar el enfoque más eficaz para optimizar el desempeño de cada modelo de IA.²¹³

Entrenamiento: Cada modelo se entrenó utilizando cinco algoritmos de aprendizaje automático para clasificación multiclase: *Random Forest* (RF), *Decision Tree* (DT), *Neural Network* (NN), *Support Vector Machine* (SVM) y *Logistic Regression* (LR). Para las pruebas, se emplearon cuatro versiones de la base de datos, asignando aleatoriamente el 80% de los datos para el entrenamiento y el 20% restante para la prueba o verificación, una práctica comúnmente utilizada para este propósito.²¹⁴

El rendimiento de cada algoritmo se evaluó mediante la métrica de exactitud (AC; *accuracy*) en cada versión de la base de datos. En la etapa de validación cruzada se incluyeron solo los dos algoritmos con mejor desempeño, junto con sus respectivas versiones de base de datos.

Validación: Se realizó una validación cruzada de cinco pasos, dividiendo aleatoriamente el conjunto de datos de entrenamiento en cinco submuestras de igual tamaño. En cada iteración, una submuestra se utilizó como conjunto de validación para evaluar el modelo, mientras que las otras cuatro se destinaron al entrenamiento. Este proceso se repitió cinco veces, evaluando el rendimiento utilizando cinco métricas

diferentes: exactitud (Ac), precisión (Pr), sensibilidad (Se), índice F1 (Fs) y especificidad (Sp). El modelo final se generó seleccionando el algoritmo y la versión de la base de datos con el mejor desempeño promedio en estas métricas.

La validación cruzada es una técnica esencial para evaluar la capacidad de generalización del modelo, ya que permite aprovechar una fracción significativa de los datos de entrenamiento para optimizar su rendimiento.²⁰⁸ Además, este proceso asegura una evaluación más precisa y confiable del desempeño del modelo frente a datos no vistos. El flujo de la metodología empleada se representa en el esquema de la Figura 6.1.

Análisis estadístico

El número de características necesarias para entrenar el algoritmo de aprendizaje automático está determinado por el tamaño del conjunto de datos. Dado que se ha empleado una técnica de validación cruzada (cross-validation) con 5 iteraciones para entrenar los algoritmos, con una muestra de 2250 ojos, el tamaño efectivo de entrenamiento debe ser de 1800 ojos (80%), y se considera aceptable que el número máximo de parámetros para un modelo con rendimiento óptimo esté limitado a una décima parte del tamaño efectivo (180).²⁰⁸ En todos los modelos entrenados, el número de variables fue claramente menor de 180, lo que indica que el tamaño de la muestra es suficiente para evaluar los algoritmos de aprendizaje automático desarrollados.




Figura 6.1. Esquema del flujo empleado en el trabajo. M1= modelo para predecir la clasificación más probable del caso; M2= modelo para predecir la localización de las patologías en diferentes segmentos oculares; M3= modelo para predecir cualquier tipo de disfunción de la VB; Od= formato original y desbalanceado; Ob= original y balanceado; Nd= normalizado y desbalanceado; Nb= normalizado y balanceado; RF=: Random Forest; DT=: Decision Tree; NN=: Neural Network; SVM= Support Vector Machine; LR= Logistic Regression; Ac= exactitud; Pr= precisión; Se= sensibilidad; Fs= índice F1; Sp= especificidad.

El rendimiento de los modelos se evaluó utilizando cinco indicadores diferentes: $\underline{Ac}$, calculada como la proporción de predicciones correctas en relación con el total de predicciones; $\underline{Pr}$ y $\underline{Se}$, calculadas como el promedio ponderado de las proporciones de verdaderos positivos en relación con el total de casos positivos verdaderos y falsos, respectivamente para cada categoría; $\underline{Fs}$, calculada como la media armónica entre precisión y sensibilidad para cada clase, ponderada por la proporción de cada categoría; y $\underline{Sp}$, calculada como el promedio simple de las proporciones de verdaderos negativos en relación con el total de negativos para cada categoría. Además, para cada métrica se realizó la prueba t para datos apareados para analizar las diferencias entre los resultados de cada iteración en la validación cruzada de los dos algoritmos probados. Se consideró un valor de $p < 0,05$ como estadísticamente significativo.²¹⁵

Finalmente, se incluyó un estudio de importancia de las características basado en la pureza adicional del nodo, utilizando el algoritmo con mejor rendimiento.²¹⁶ Este enfoque permitió identificar los predictores más relevantes e impactantes en los modelos propuestos.



6.3. Resultados

Estructuración de la base de datos

Se han recopilado un total de 1125 registros en fichas clínicas a lo largo de 10 años correspondiendo los años 2015 (n=241; 21,4%) y 2021 (n=50; 4,4%) a los de mayor y menor cantidad de registros respectivamente (Tabla 6.2-A). No se incluyeron datos correspondientes al año 2020 debido a las restricciones impuestas por la pandemia de COVID-19, que afectaron el funcionamiento de la clínica. En total se generaron 253 campos para cada ficha incluida que fueron clasificados en 15 categorías.

En la modelización de la base de datos inicial (BDi) se excluyeron 29 campos considerados irrelevantes para los objetivos del estudio, como aquellos con datos poco frecuentes (como el test de visión cromática, por ejemplo) o que correspondían a información interna de la clínica. Asimismo, se descartaron campos con información recogida exclusivamente por estudiantes. Los registros fueron separados por ojo, creando así campos de control para gestionar casos con características exclusivamente monoculares, puesto que el protocolo académico de la clínica obligaba a registrar separadamente tanto los exámenes como los diagnósticos y los tratamientos separadamente por ojo.

Para los datos originalmente descriptivos, se generaron nuevos campos, especialmente en las categorías de anamnesis, historial y

biomicroscopía, donde cada visita fue cuidadosamente clasificada y segmentada para ser convertida en variables sí o no. Este proceso de modelización incrementó el número de campos recogidos en las categorías de Anamnesis (de 6 a 38), de Historia personal/familiar (de 2 a 30) y de Biomicroscopía (de 7 a 47) (Tabla 6.2-B). Finalmente, la BDi después del modelado, quedó compuesta por 2240 registros y 214 campos (Tabla 6.2-B), que a partir de ahora se denomina "Base de datos modelada" (BDm).

Tabla 6.2. Resumen descriptivo de la etapa de estructuración de los datos. **A:** Distribución y perfil de los datos recolectados. **B:** La base de datos inicial (recolección) y la modelada se presentan según la categoría de los campos, con colores que indican los grupos: Amarillo claro (Datos preliminares), Amarillo (Historial), Naranja (Pruebas oculomotoras), Marrón (Exámenes oculares), Azul (pruebas refractivas) y Gris oscuro (decisiones clínicas).

A Historial			B Recogida Modelado		
Año	n	%	<u>Categoría de los campos</u> <u>Características</u>		
2012	189	16,8%	Control	2	3
2013	110	9,8%	General	3	5
2014	110	9,8%	Agudeza visual	14	4
2015	241	21,4%	Anamnesis	6	38
2016	135	12,0%	Historial personal / familiar	2	30
2017	117	10,4%	Exámenes motores	47	12
2018	103	9,2%	Oftalmoscopía	16	10
2019	70	6,20	Biomicroscopía	7	47
2020	0	0%	Queratometría	2	6
2021	50	4,4%	Retinoscopía	107	18
Total	1125	100%	Diagnóstico	9	29
			Manejo	9	12
			Irrelevantes	29	0
			Total (columnas)	253	214
			Registros (líneas)	1125	2240
Sexo	n	%			
Femenino	708	62,9			
Masculino	417	37,1			
Edad	35,0 ± 19,6				

A partir de la BDm, se planificaron subconjuntos de datos específicos para el desarrollo de los modelos previstos (M1, M2 y M3), tal y como se detalla en la Figura 6.2.

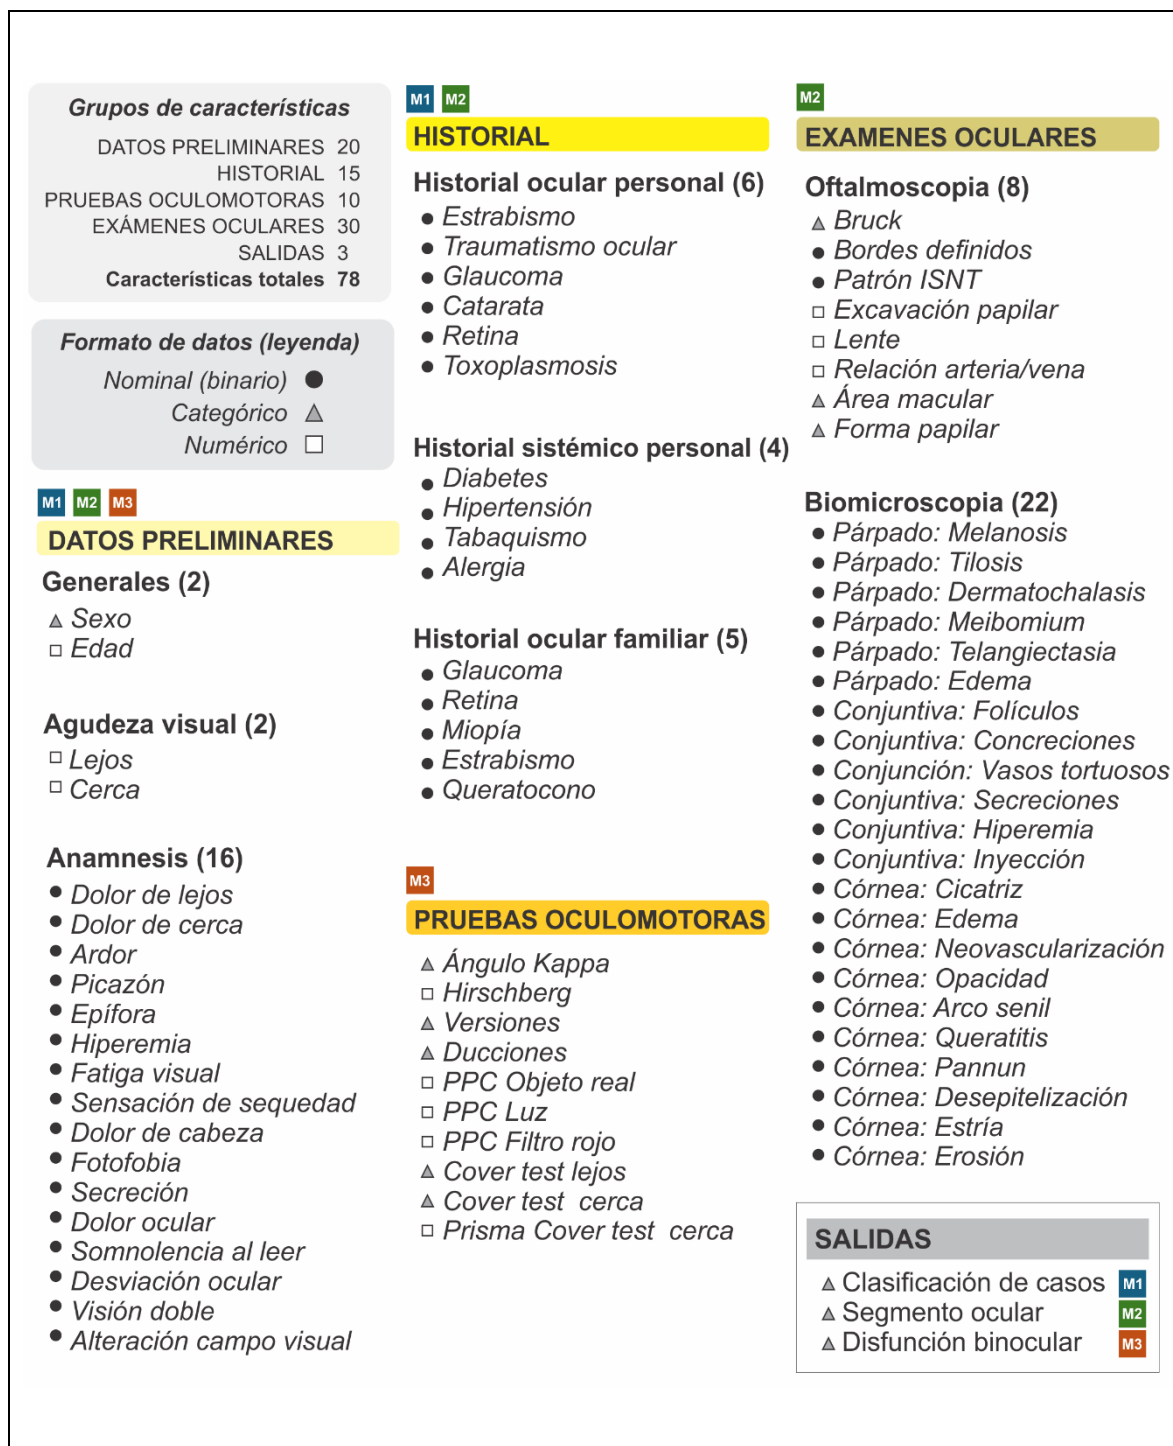


Figura 6.2. Resumen de las características de los datos de entrada y salida utilizados para desarrollar los tres modelos (M1, M2 y M3) de IA.

En total se seleccionaron 75 características de entrada en formatos binario, categórico y numérico, distribuidas en diferentes grupos como *datos preliminares*, *historia clínica* (que incluyen las categorías de características generales, AV, anamnesis, antecedentes personales y familiares oculares y/o sistémicos), *pruebas oculomotoras* (incluyendo acomodación, *cover test* (CT), vergencias fusionales, test de Hirschberg y punto próximo de convergencia (PPC) cercano) y *exámenes oculares* (que incluyen datos de la oftalmoscopia y evaluación biomicroscópica del polo anterior).

Aunque incluidos en la BDm, los datos correspondientes al grupo de *pruebas refractivas* no fueron necesarios para el desarrollo específico de los modelos previstos.

Por su parte, en el grupo de *decisión clínica*, solo se utilizaron como resultados (*salida*) aquellos datos relacionados tanto con la clasificación del caso como con la localización en el segmento ocular de la alteración además del tipo de disfunción binocular para realizar la implementación de las predicciones.

Ciclo de desarrollo de IA

El desarrollo de los modelos de IA incluye tres etapas diferenciadas para el preprocesamiento de los datos, el entrenamiento de los algoritmos y finalmente su validación y a continuación se detallan los resultados de cada una de estas etapas.

Preprocesamiento: El modelo M1 empleó 35 características de "datos preliminares" e "historial" para clasificar los casos, el modelo M2 subclasificó la localización de los trastornos oculares empleando 65 características correspondientes a "datos preliminares", "historial" y

"exámenes oculares" y finalmente el modelo M3 empleó 30 características correspondientes a "datos preliminares" y "pruebas oculomotoras" para diferenciar entre disfunción binocular o acomodativa.

Tras el preprocesamiento, se obtuvieron 2214 (M1), 2206 (M2) y 1982 (M3) registros desbalanceados que tras el balanceo (SMOTE) quedaron en 8176 (M1), 6532 (M2) y 6264 (M3), respectivamente, tal y como se describe en la Tabla 6.3, que resume los resultados del preprocesamiento.

Entrenamiento: Las métricas de análisis mostraron que los algoritmos SVM y LR tenían el peor desempeño en todas las pruebas. Por el contrario, los mejores resultados los obtuvo el algoritmo RF, alcanzando precisiones del 94,6% (M1), 97,1% (M2) y 99,4% (M3), seguido por el algoritmo DT en el M1 (90,0%) y el algoritmo NN en el M2 (95,2%) y M3 (97,3%), como se presenta en la Tabla 6.4.

En lo que respecta a las versiones de las bases de datos, el mejor desempeño se observó en los datos balanceados para todos los modelos. Respecto a la normalización de los datos, el algoritmo RF no mostró diferencias significativas entre los datos normalizados y los originales (no normalizados), por lo que se optó por emplear la versión original para la etapa de validación cruzada. Por el contrario, los segundos mejores desempeños en todos los modelos, DT en M1 y NN en M2 y M3, se consiguieron con la versión normalizada de los datos.

Tabla 6.3. Resumen descriptivo del resultado del preprocesamiento del conjunto de datos utilizados para entrenar los modelos M1, M2 y M3.

Conjunto de datos		n	Edad (años)	Sexo (M/H)	Clasificación de casos			Entradas	
					Refractivo	Visión binocular	Enferm. Oculares/ Sistémicas		
Todas las muestras		2250	35 ± 20	63% 37%	87,6%	22,4%	32,4%	75	
Clasificación de casos									
M1	desbalanceado	Total	2214	35 ± 19	63% 37%	87,7%	22,4%	32,4%	35
		Entren.	1771	35 ± 19	63% 37%	87,4%	22,6%	32,3%	
		Prueba	443	36 ± 20	65% 35%	88,9%	21,7%	32,7%	
	balanceado	Total	8176	28 ± 19	60% 40%	50,0%	50,0%	50,0%	
		Entren.	6540	28 ± 19	60% 40%	49,7%	50,1%	49,9%	
		Prueba	1636	29 ± 19	60% 40%	51,1%	49,6%	50,2%	
Clasificación del segmento del trastorno ocular									
M2	desbalanceado	Total	2206	35 ± 19	63% 37%	-	-	26,0%	65
		Entren.	1746	35 ± 19	63% 37%	-	-	25,9%	
		Prueba	442	36 ± 19	64% 36%	-	-	26,2%	
	balanceado	Total	6532	40 ± 20	52% 48%	-	-	75,0%	
		Entren.	5225	40 ± 20	52% 48%	-	-	74,4%	
		Prueba	1307	40 ± 20	52% 48%	-	-	74,4%	
Clasificación de disfunción de la visión binocular									
M3	desbalanceado	Total	1982	35 ± 19	63% 37%	-	21,0%	-	30
		Entren.	1585	35 ± 19	63% 37%	-	21,4%	-	
		Prueba	397	36 ± 19	65% 35%	-	19,4%	-	
	balanceado	Total	6.264	28 ± 18	64% 36%	-	75,0%	-	
		Entren.	5011	28 ± 18	63% 37%	-	75,1%	-	
		Prueba	1253	27 ± 18	65% 35%	-	74,5%	-	

Tabla 6.4. Resumen de la exactitud en los algoritmos y versiones de bases de datos para cada modelo desarrollado (M1, M2 y M3). Los algoritmos (columna izquierda) con mejores resultados se presentan con fondo gris. Los resultados se destacan con un código de colores del verde al rojo, destacando los mejores resultados con fondo en tonos verdes y negrita, los peores resultados con fondo rojos y subrayados y los que tienen resultados intermedios con fondo amarillos.

Versión del conjunto de datos		Desbalanceado		Balanceados		Promedio general
		Original	Normaliz.	Original	Normaliz.	
M1	<i>n</i> (training / test)	2214 (1771 / 443)		8176 (6540 / 1636)		-
Random forest (RF)		83,1%	82,8%	94,6%	94,6%	88,8%
Decision Tree (DT)		71,3%	71,3%	89,8%	90,0%	80,6%
Neural network (NN)		59,1%	78,6%	77,3%	84,6%	74,9%
Support Vector Machines (SVM)		49,4%	54,6%	<u>32,4%</u>	64,3%	50,2%
Logistic Regression (LR)		47,9%	47,4%	39,9%	<u>39,2%</u>	43,6%
M2	<i>n</i> (training / test)	2206 (1764 / 442)		6532 (5225 / 1307)		-
Random forest (RF)		89,4%	89,4%	97,1%	97,1%	93,2%
Decision Tree (DT)		81,0%	81,0%	92,0%	92,0%	86,5%
Neural network (NN)		90,0%	91,2%	94,7%	95,2%	92,8%
Support Vector Machines (SVM)		73,8%	75,6%	<u>51,2%</u>	88,8%	72,3%
Logistic Regression (LR)		73,3%	73,5%	71,1%	<u>70,4%</u>	72,0%
M3	<i>n</i> (training / test)	1982 (1585 / 397)		6264 (5011 / 1253)		-
Random forest (RF)		95,5%	95,5%	99,4%	99,4%	97,5%
Decision Tree (DT)		90,9%	90,7%	95,1%	95,1%	93,0%
Neural network (NN)		91,4%	93,5%	96,6%	97,3%	94,8%
Support Vector Machines (SVM)		80,6%	80,9%	<u>52,7%</u>	83,8%	74,5%
Logistic Regression (LR)		80,1%	80,9%	53,2%	<u>52,4%</u>	66,7%

Validación: De forma general, el algoritmo RF demostró un desempeño significativamente superior en los tres modelos desarrollados, mientras que los algoritmos DT (en M1) y NN (en M2 y M3) obtuvieron resultados inferiores.

A continuación, se presentan los detalles específicos de la validación de cada modelo (M1, M2 y M3), incluidos los resultados de la validación cruzada, así como los gráficos que ilustran el desempeño del mejor modelo.

M1: El algoritmo RF mostró un rendimiento superior al DT en todas las validaciones y en todas las métricas evaluadas. La exactitud promedio de RF alcanzó un 95,7%, mientras que DT obtuvo un valor del 90,1%, con diferencias estadísticamente significativas en todas las métricas ($p < 0,001$), como se muestra en la Tabla 6.5.

La Figura 6.3 presenta una perspectiva detallada del rendimiento del mejor modelo (RF), destacando su desempeño. En el gráfico (6.3.A) se resalta la consistencia del algoritmo RF en la mayoría de las categorías analizadas, evidenciando su capacidad para mantener métricas altas, con excepción de las respuestas “Refractivas”, cuya sensibilidad fue próxima al 80%. Este resultado indica una ligera variación en el rendimiento del modelo al clasificar esta categoría específica. La curva de precisión y sensibilidad (6.3.B) muestra que la mayoría de las clasificaciones alcanzaron un valor de 0,99, lo que refleja un buen balance en términos de desempeño, con excepción de la clase “Refractiva”, cuya precisión fue ligeramente inferior (0,93). Por otro lado, la matriz de confusión (C) destaca la categoría “Oculomotor y Patología” con el mayor número de aciertos (215), lo que demuestra su alta precisión, mientras que la categoría “Refractiva” registró el menor número de aciertos (175), evidenciando un desempeño menos consistente en esta categoría.

Tabla 6.5. Resumen de las métricas del modelo 1 (M1) en las iteraciones de la validación cruzada (k1 a k5) en los mejores algoritmos y formato de datos, con promedios (Prom) y desviaciones estándar (DE) para el algoritmo Random Forest (RF) y Decision Tree (DT). La parte inferior de la tabla muestra la comparación entre ambos algoritmos destacando el mejor desempeño en negrita y fondo gris oscuro entre ambos algoritmos para todas las métricas de análisis.

RF [Ob]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,954	0,969	0,957	0,959	0,947	0,957	0,007
Pr	0,955	0,969	0,957	0,959	0,947	0,957	0,007
Se	0,954	0,969	0,957	0,959	0,947	0,957	0,007
Fs	0,954	0,969	0,956	0,959	0,947	0,957	0,007
Sp	0,955	0,969	0,957	0,959	0,947	0,957	0,007
<i>Prom.</i>	0,955	0,969	0,957	0,959	0,947	0,957	0,007

DT [Nb]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,899	0,905	0,909	0,895	0,898	0,901	0,005
Pr	0,899	0,906	0,910	0,893	0,897	0,901	0,006
Se	0,899	0,905	0,909	0,895	0,898	0,901	0,005
Fs	0,899	0,905	0,909	0,894	0,897	0,901	0,006
Sp	0,899	0,906	0,910	0,893	0,897	0,901	0,006
<i>Prom.</i>	0,899	0,906	0,910	0,894	0,897	0,901	0,006

M1	Random Forest - RF [Ob]	Decision Tree - DT [Nb]	p value
Ac	95,7% ± 0,7%	90,1% ± 0,5%	< 0.001
Pr	95,7% ± 0,7%	90,1% ± 0,6%	< 0.001
Se	95,7% ± 0,7%	90,1% ± 0,5%	< 0.001
Fs	95,7% ± 0,7%	90,1% ± 0,6%	< 0.001
Sp	95,7% ± 0,7%	90,1% ± 0,6%	< 0.001
<i>Prom.</i>	95,7% ± 0,7%	90,1% ± 0,6%	< 0,001




Figura 6.3. Resumen de las métricas de rendimiento del modelo M1. **A:** Desempeño de las métricas de clasificación por categoría. **B:** Curva de precisión y sensibilidad para diferentes clasificaciones. **C:** Matriz de confusión.

M2: El modelo RF demostró un desempeño superior al NN durante la validación cruzada, destacándose en precisión, sensibilidad y especificidad. La exactitud promedio registrada por RF fue del 98,2%, en comparación con el 97,1% obtenido por NN, con diferencias estadísticamente significativas entre ambos modelos ($p < 0,01$), tal como se muestra en la Tabla 6.6. Aunque la diferencia fue pequeña, se mantuvo constante a través de todas las validaciones evaluadas.

La Figura 6.4 ilustra el rendimiento del modelo RF (M2), donde se observa que el algoritmo mantiene un rendimiento consistente en la mayoría de las clases, aunque con una ligera variación en la sensibilidad de la clase “Ninguno” (6.4.A). El gráfico (6.4.B) destaca el equilibrio en las métricas, donde casi todas las categorías alcanzaron valores óptimos ($\geq 0,99$), excepto “Ninguno”, con 0,98. La matriz de confusión (6.4.C) muestra que el mayor número de aciertos fue en la clasificación “Polo anterior y posterior” (328), sin errores; en contraste con la clase “Ninguno” que registró 316 aciertos y 19 errores.

Tabla 6.6. Resumen de las métricas del modelo 2 (M2) en las iteraciones de la validación cruzada (k1 a k5) en los mejores algoritmos y formato de datos, con promedios (Prom) y desviaciones estándar (DE) para el algoritmo Random Forest (RF) y Neural Network (NN). La parte inferior de la tabla muestra la comparación entre ambos algoritmos destacando el mejor desempeño en negrita y fondo gris oscuro entre ambos algoritmos para todas las métricas de análisis.

RF [Ob]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,940	0,990	0,991	0,992	0,994	0,981	0,021
Pr	0,949	0,990	0,991	0,992	0,994	0,983	0,017
Se	0,940	0,990	0,991	0,992	0,994	0,981	0,021
Fs	0,941	0,990	0,991	0,992	0,994	0,982	0,020
Sp	0,949	0,990	0,991	0,992	0,994	0,983	0,017
Prom.	0,944	0,990	0,991	0,992	0,994	0,982	0,019

NN [Nb]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,933	0,974	0,982	0,983	0,982	0,971	0,019
Pr	0,939	0,974	0,982	0,983	0,982	0,972	0,017
Se	0,933	0,974	0,982	0,983	0,982	0,971	0,019
Fs	0,933	0,974	0,982	0,983	0,982	0,971	0,019
Sp	0,939	0,974	0,982	0,983	0,982	0,972	0,017
Prom.	0,935	0,974	0,982	0,983	0,982	0,971	0,018

M2	<i>Randon Forest - RF [Ob]</i>	<i>Neural Network - NN [Nb]</i>	<i>p value</i>
Ac	98,2% ± 2,0%	97,1% ± 1,9%	< 0,01
Pr	98,3% ± 1,7%	97,2% ± 1,7%	< 0,01
Se	98,1% ± 2,1%	97,1% ± 1,9%	< 0,01
Fs	98,2% ± 2,0%	97,1% ± 1,9%	< 0,01
Sp	98,3% ± 1,7%	97,2% ± 1,7%	< 0,01
Prom.	98,2% ± 1,9%	97,1% ± 1,8%	< 0,01




Figura 6.4. Resumen de las métricas de rendimiento del modelo M2. **A:** Desempeño de las métricas de clasificación por categoría. **B:** Curva de precisión y sensibilidad para diferentes clasificaciones. **C:** Matriz de confusión.

M3: Nuevamente, el algoritmo RF alcanzó los valores más altos entre los modelos evaluados. La exactitud promedio fue del 99,7%, superando al modelo NN, que obtuvo un 97,5% ($p < 0,01$). La robustez del modelo RF se confirma en la validación cruzada, donde se obtuvieron valores superiores a 0,998 en 4 de las validaciones cruzadas, con una ligera reducción en el primero, que alcanzó un valor de 0,991 (Tabla 6.7).

La Figura 6.5 ilustra el rendimiento del modelo RF (M3). En el gráfico (6.5.A), muestra que la mayoría de las clasificaciones lograron métricas cercanas al máximo (1,00), destacando la consistencia general del algoritmo. La curva de precisión y sensibilidad (6.5.B) evidencia el balance óptimo entre ambas métricas, mientras que en la matriz de confusión (6.5.C) resaltan las clases “Disfunción acomodativa y de vergencia” y “Disfunción acomodativa” por su ausencia total de errores, en contraste con la clase “Disfunción de vergencia” que registró 6 errores.

Tabla 6.7. Resumen de las métricas del modelo 3 (M3) en las iteraciones de la validación cruzada (k1 a k5) en los mejores algoritmos y formato de datos, con promedios (Prom) y desviaciones estándar (DE) para el algoritmo Random Forest (RF) y Neural Network (NN). La parte inferior de la tabla muestra la comparación entre ambos algoritmos destacando el mejor desempeño en negrita y fondo gris oscuro entre ambos algoritmos para todas las métricas de análisis.

RF [Ob]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,990	0,999	0,999	0,999	0,998	0,997	0,003
Pr	0,991	0,999	0,999	0,999	0,998	0,997	0,003
Se	0,990	0,999	0,999	0,999	0,998	0,997	0,003
Fs	0,990	0,999	0,999	0,999	0,998	0,997	0,003
Sp	0,991	0,999	0,999	0,999	0,998	0,997	0,003
Prom.	0,991	0,999	0,999	0,999	0,998	0,997	0,003

NN [Nb]	k1	k2	k3	k4	k5	<i>Prom.</i>	<i>DE</i>
Ac	0,955	0,986	0,977	0,974	0,985	0,975	0,011
Pr	0,956	0,986	0,977	0,975	0,985	0,976	0,011
Se	0,955	0,986	0,977	0,974	0,985	0,975	0,011
Fs	0,955	0,986	0,977	0,974	0,985	0,975	0,011
Sp	0,956	0,986	0,977	0,975	0,985	0,976	0,011
Prom.	0,956	0,986	0,977	0,974	0,985	0,975	0,011

M3	Random forest - RF [Ob]	Neural network - NN [Nb]	p value
Ac	99,7% $\pm$ 0,3%	97,5% $\pm$ 1,10%	< 0,01
Pr	99,7% $\pm$ 0,3%	97,6% $\pm$ 1,07%	< 0,01
Se	99,7% $\pm$ 0,3%	97,5% $\pm$ 1,10%	< 0,01
Fs	99,7% $\pm$ 0,3%	97,5% $\pm$ 1,10%	< 0,01
Sp	99,7% $\pm$ 0,3%	97,6% $\pm$ 1,07%	< 0,01
Prom.	99,7% $\pm$ 0,3%	97,5% $\pm$ 1,09%	< 0,01




Figura 6.5. Resumen de las métricas de rendimiento del modelo M3. **A:** Desempeño de las métricas de clasificación por categoría. **B:** Curva de precisión y sensibilidad para diferentes clasificaciones. **C:** Matriz de confusión.

La importancia de las características individuales en los tres modelos se muestra en la Figura 6.6, donde en la columna A (izquierda) se muestra el número de variables que contribuyen al 95% o más de cada modelo (15 variables en el M1, 34 en el M2 y 18 en el M3) mientras que en la columna B (derecha) se destacan las 15 variables con mayor contribución (95,4% en el M1, 72,4% en el M2 y 90,6% en el M3), destacando la edad del paciente como el predictor más significativo de forma consistente en todos los modelos.




Figura 6.6. Resumen de las características más relevantes en cada modelo: el panel superior corresponde al M1, el central M2 y el inferior M3. A la izquierda (A)

se presenta una descripción general ordenada de la importancia de las características en cada modelo (la línea discontinua marca el punto donde se alcanza al menos el 95% de importancia), y a la derecha (B) se presenta un desglose de las 15 características principales más relevantes en cada modelo y el porcentaje de importancia que alcanzan estas variables. ISNT= inferior, superior, nasal, temporal; Conj: Conjuntiva; PPC= Punto próximo de convergencia; CT= Cover test; AV= Agudeza visual.



6.4. Discusión

El uso de la IA en Optometría y Oftalmología se ha centrado principalmente en el diagnóstico de enfermedades oculares de polo posterior,^{203,205} con aplicaciones más limitadas en el diagnóstico basado en imágenes del segmento anterior del ojo²⁰⁷ y en la refracción ocular.^{208,209} Los algoritmos ML y DL desarrollados en este trabajo han mostrado rendimientos comparables a los previamente descritos en otros estudios (superiores al 95% con el algoritmo RF en diferentes condiciones oculares²¹⁷). Por ejemplo, las redes neuronales convolucionales (CNN) han demostrado ser capaces de detectar la retinopatía diabética referible con una sensibilidad entre el 91,7% y el 97,2%^{218,219} y con una exactitud que oscila entre el 91% y el 96% para la detección de la degeneración macular relacionada con la edad,^{220,221} o del 90% al 99,5% en la identificación del queratocono.^{222–224} Otros algoritmos de ML han alcanzado valores del 97,6% y el 95,4% en la evaluación de las glándulas de Meibomio²²⁵ y en las mediciones del espesor del menisco lagrimal.²²⁶ Estos algoritmos también han demostrado gran utilidad en su aplicación en la enfermedad del glaucoma,²¹⁷ clasificando imágenes de fondo de ojo en color para identificar estadios leves de glaucoma con precisión entre el 91,4% y el 98,2%,^{227–229} discriminando entre nervios ópticos glaucomatosos y los de ojos sanos mediante OCT con precisiones del 90,2% al 96,6%^{230,231} y detectando la progresión del daño glaucomatoso con una sensibilidad

del 85%.^{232,233} Por su parte, en pacientes pediátricos, los algoritmos de ML han mostrado alta sensibilidad y especificidad para detectar la retinopatía del prematuro (93%),^{234,235} cataratas congénitas (94,4% a 98,9%)²³⁶ o ambliopía (81,6%).²³⁷ Otros sistemas previos de apoyo a la toma de decisiones clínicas propuestos para su uso por profesionales de atención primaria de la visión,²³⁸ oftalmólogos^{90,239} o estudiantes de ciencias de la salud²⁴⁰ no han incorporado la IA.

Es importante diferenciar el enfoque de los modelos propuestos en la literatura y en este trabajo, de aquellos otros modelos de lenguaje generativo a gran escala (LLM) como *ChatGPT*, que se entrenan en grandes volúmenes de datos generales y están diseñados para generar textos informativos en diversos contextos, incluida la salud visual.²⁴¹ Sin embargo, estos modelos no están optimizados para apoyar la toma de decisiones en contextos clínicos específicos. En contraste, los modelos predictivos propuestos en esta Tesis Doctoral han sido diseñados y entrenados específicamente con datos clínicos tabulados para proporcionar un soporte preciso y seguro en la toma de decisiones del cuidado de la salud visual a nivel primario.

En este trabajo, se han entrenado diversos modelos de ML para predecir la salud ocular utilizando pruebas clínicas. El proceso incluyó etapas clave como el modelado, preprocesamiento, entrenamiento y validación con evaluación del desempeño según métricas adecuadas en el desarrollo y validación de este tipo de algoritmos.¹³¹ El algoritmo RF ha resultado ser el mejor modelo, con una precisión superior al 95%, demostrando un alto potencial para su aplicación tanto en la práctica de atención ocular primaria como en la formación preclínica de estudiantes de ciencias de la visión.

La detección temprana de problemas oculares de origen refractivo o patológico es esencial, ya que la visión tiene un impacto significativo en el bienestar y la calidad de vida de las personas.²⁴² Se estima que más de mil millones de personas en todo el mundo padecen problemas de visión moderados o graves, o incluso ceguera, causados por condiciones evitables o potencialmente corregibles, como errores de refracción, presbicia o cataratas.²⁴² Además, se prevé que para 2050 más de 2000 millones de personas en todo el mundo tendrán más de 60 años, residiendo la mayoría de ellas en países de bajos o medios ingresos.²⁴³ Dado que existe una relación clara entre la edad y ciertas enfermedades oculares,⁶⁵ como la retinopatía diabética, el glaucoma, la degeneración macular relacionada con la edad o las cataratas, proporcionar una atención adecuada y una detección temprana de estas enfermedades en pacientes mayores generará importantes desafíos para los sistemas de salud, aumentando los costos de atención sanitaria. En este contexto, los algoritmos de ML han sido propuestos como herramientas prometedoras para la detección de enfermedades oculares altamente prevalentes, como parte de la estrategia para abordar la escasez de personal especializado y con experiencia para desarrollar estas tareas de atención visual.²⁴³

Por lo tanto, es fundamental implementar estrategias efectivas de detección y toma de decisiones clínicas para ampliar y/o mejorar el acceso a la salud visual, especialmente en regiones con acceso limitado a profesionales del cuidado ocular, como optometristas u oftalmólogos, garantizando que los pacientes reciban una atención necesaria de forma oportuna y precisa.²⁴⁴ En este contexto, el uso de tecnologías avanzadas aplicadas al cuidado ocular representa una valiosa oportunidad para superar los desafíos a los que se enfrenta el modelo

de atención sanitaria tradicional. Estas tecnologías permiten herramientas de apoyo a la toma de decisiones clínicas que asistan a optometristas, oftalmólogos y otros profesionales de la salud, facilitando un enfoque personalizado y eficiente del cuidado visual, que puede ayudar a reducir los tiempos de espera y mejorar el acceso a los especialistas.²⁴⁵

El primer modelo desarrollado (M1) permite clasificar a los pacientes para identificar el tipo de problema ocular (refracción, enfermedad ocular o disfunción de la VB) basándose en pequeñas cantidades de información obtenida en un examen preliminar, que incluye la historia ocular y familiar del paciente, la anamnesis y la medida de la AV, facilitando la detección temprana de condiciones oculares. En este modelo, las características más relevantes fueron la edad, la AV a distancias lejanas y cercanas, y el sexo, seguidas por síntomas como dolor ocular, picor, dolor de cabeza, quejas de visión lejana y cercana, ardor y fotofobia, que mostraron una relevancia similar (Figura 6.6, panel superior).

El M2, diseñado para identificar la posible ubicación de enfermedades oculares, tiene un amplio potencial de aplicación por parte de diferentes profesionales sanitarios (Tabla 6.6 y Figura 6.4). Este modelo permite la subclasificación de las enfermedades oculares sospechadas en categorías como polo anterior, posterior o ambos polos, lo que puede resultar de gran utilidad en los procesos de derivación ayudando a reducir significativamente los tiempos de espera y facilitando a los pacientes el acceso a especialistas adecuados. En este modelo, las características con más impacto fueron la edad, las quejas de visión lejana y el sexo, seguidas de signos clínicos

relacionados con la excavación y forma papilar. Además, el estado del cristalino, la AV a distancias lejanas y cercanas, el dolor de cabeza, los resultados de la prueba de Bruck, la hipertensión, los bordes del disco óptico, la hiperemia conjuntival y las quejas de visión cercana también fueron relevantes (Figura 6.6, panel medio).

El M3, por su parte, permite la subclasificación de disfunciones de la VB en aquellas relacionadas con la acomodación o con una disfunción de la vergencia fusional, lo que podría beneficiar significativamente el manejo clínico de estos pacientes (Tabla 6.7 y Figura 6.5). En este modelo, las características más relevantes fueron la edad y las pruebas oculomotoras, como el PPC (realizado con objeto real, luz y filtro rojo) y el CT (a distancia cercana y con prisma), seguidas de la AV lejana y cercana, el sexo, el ángulo Kappa, el CT a distancia lejana, el dolor de cabeza, el ardor, y las quejas de visión lejana y cercana (Figura 6.6, panel inferior).

Este análisis sugiere que los modelos desarrollados tienen un alto potencial para una mayor optimización, especialmente al identificar las características más relevantes (más del 95% de importancia) en cada modelo - 43% en M1 (15/35), 52% en M2 (34/65) y 60% en M3 (18/30)- lo que podrá mejorar los modelos a partir de estos predictores claves.

Sin embargo, el uso de algoritmos de IA no está exento de consideraciones técnicas y clínicas, y esta investigación presenta ciertas limitaciones. En primer lugar, los datos clínicos utilizados provienen de un único centro con un perfil específico (clínica universitaria) y la cantidad de datos fue limitada. Esto plantea un desafío en cuanto a la generalización del modelo desarrollado, que podría requerir evaluaciones adicionales. Por lo tanto, se necesitan

investigaciones futuras con muestras más amplias, considerando colaboraciones multicéntricas y multiétnicas. Estas poblaciones son esenciales para evaluar la aplicabilidad clínica real de los modelos desarrollados en el contexto del mundo real. Además, es fundamental determinar la precisión, fiabilidad, robustez y estabilidad de los modelos, evaluando su generalización (evitando el sobreajuste (*overfitting*), que ocurre cuando el modelo se ajusta demasiado a los datos de entrenamiento y puede hacer que no funcione bien con nuevos datos) y su utilidad clínica en entornos de tiempo real. Esto requiere pruebas con nuevos conjuntos de datos con diferencias temporales, geográficamente diversos, longitudinales (seguimiento) y externos. A esto se suma la complejidad, o incluso la imposibilidad, de interpretar algoritmos como las NN o el RF, entre otros, lo que representa un obstáculo significativo que podría retrasar su aceptación y limitar la transparencia en el diagnóstico.²⁴⁶

Con una mayor diversidad de datos, sería posible disminuir la dependencia de las técnicas de balanceo de datos, que, aunque útiles para abordar desequilibrios en los conjuntos de datos, pueden introducir sesgos y afectar la precisión de los resultados.⁵⁷ Sin embargo, la recopilación de datos clínicos en el ámbito de la atención optométrica y/u oftalmológica carece de estandarización, y las variaciones entre profesionales y centros pueden influir negativamente en la calidad y consistencia de los datos. Establecer estándares en la recopilación, modelado y preprocesamiento de datos podría facilitar el intercambio entre centros, aumentar la colaboración en red y garantizar el cumplimiento de las normativas estatales sobre privacidad. Asimismo, es esencial garantizar la anonimización de los datos y obtener el consentimiento informado de los pacientes antes de compartir cualquier

información. La recopilación de grandes cantidades de datos multicéntricos también requiere soluciones técnicas para garantizar un almacenamiento seguro y una gestión eficiente de la información. Además, existen consideraciones éticas asociadas al uso de aplicaciones de DL en la práctica médica, tales como el sesgo racial en el desarrollo de algoritmos o la responsabilidad frente a diagnósticos erróneos^{31,32,247} que tienen que ser valoradas adecuadamente.

Finalmente, el futuro desarrollo de nuevos modelos aplicados a la atención visual primaria podría ampliar significativamente su alcance clínico a otras áreas, como el control de la enfermedad del ojo seco o el control de la progresión de la miopía, entre otros ejemplos. Además, sería posible explorar otras técnicas de modelado, incluyendo bibliotecas de aprendizaje profundo e imágenes como fuente de datos. Esto abriría camino a una integración plausible con dispositivos y equipos médicos, facilitando el desarrollo de innovaciones tecnológicas aplicadas a la salud visual.

6.5. Difusión

Parte de los resultados de este capítulo se publicaron en formato de artículo en la revista *Ophthalmic and Physiological Optics* (Figura 6.7).

Stuermer L, Braga S, Martin R, Wolffsohn JS. **Artificial intelligence virtual assistants in primary eye care practice.** *Ophthalmic Physiol Opt.* 2025;45:437–449. doi: 10.1111/opo.13435
(Factor de impacto: 2,8 – Q1 SCIE)



Resultados preliminares de este capítulo fueron presentados en el congreso OPTOM 2022 en formato de comunicación oral.

28º Congreso Internacional de Optometría, Contactología y Óptica Oftálmica - OPTOM2024. Comunicación Oral: **Asistente virtual basado en modelos de inteligencia artificial para apoyar la toma de decisión en atención visual primaria.** Stuermer L, Braga S, Martín R. al 14 de abril de 2024. (España).



Received: 21 September 2024 | Accepted: 16 December 2024 | Published online: 26 December 2024
DOI: 10.1111/opo.13435

ORIGINAL ARTICLE

OPO  THE COLLEGE OF OPTOMETRISTS

Artificial intelligence virtual assistants in primary eye care practice

Leandro Stuermer^{1,2}  | Sabrina Braga^{1,2}  | Raul Martin^{2,3}  | James S. Wolffsohn⁴ 

¹Department of Optometry, University of Contestado, Canoinhas, Brazil
²Optometry Research Group, School of Optometry, IOBA Eye Institute, University of Valladolid, Valladolid, Spain
³Departamento de Física Teórica, Atómica y Óptica, Universidad de Valladolid, Valladolid, Spain
⁴Optometry and Vision Sciences Research Group, Aston University, Birmingham, UK

Correspondence
Raul Martin, IOBA Eye Institute, University of Valladolid, Valladolid, Spain.
Email: raul@ioba.med.uva.es

Abstract
Purpose: To propose a novel artificial intelligence (AI)-based virtual assistant trained on tabular clinical data that can provide decision-making support in primary eye care practice and optometry education programmes.
Method: Anonymised clinical data from 1125 complete optometric examinations (2250 eyes; 63% women, 37% men) were used to train different machine learning algorithm models to predict eye examination classification (refractive, binocular vision dysfunction, ocular disorder or any combination of these three options). After modelling, adjustment, mining and preprocessing (one-hot encoding and SMOTE techniques), 75 input (preliminary data, history, oculomotor test and ocular examinations) and three output (refractive, binocular vision status and eye disease) features were defined. The data were split into training (80%) and test (20%) sets. Five machine learning algorithms were trained, and the best algorithms were subjected to fivefold cross-validation. Model performance was evaluated for accuracy, precision, sensitivity, F1 score and specificity.
Results: The random forest algorithm was the best for classifying eye examination results with a performance >95.2% (based on 35 input features from preliminary data and history), to propose a subclassification of ocular disorders with a performance >98.1% (based on 65 features from preliminary data, history and ocular examinations) and to differentiate binocular vision dysfunctions with a performance >99.7% (based on 30 features from preliminary data and oculomotor tests). These models were integrated into a responsive web application, available in three languages, allowing intuitive access to the AI models via conventional clinical terms.
Conclusions: An AI-based virtual assistant that performed well in predicting patient classification, eye disorders or binocular vision dysfunction has been developed with potential use in primary eye care practice and education programmes.

KEYWORDS
artificial intelligence, clinical decision support, machine learning, optometry, virtual assistant

INTRODUCTION

Artificial intelligence (AI) seeks to imitate human thought in a previously unprogrammed way through the manipulation of data through different machine learning (ML) algorithms, deep learning (DL) and a variety of neural networks (NNs).¹ In the fields of optometry and ophthalmology, there has been strong interest from researchers because AI can improve the diagnosis, therapeutic management and care of several eye conditions,² primarily related to posterior eye disorders (such as diabetic retinopathy, age-related macular degeneration and glaucoma but also to detect retinopathy of prematurity³ or macular hole assessment⁴). Additionally, AI can be applied to anterior segment

This is an open access article under the terms of the [Creative Commons Attribution-NonCommercial-NoDerivs](#) License, which permits use and distribution in any medium, provided the original work is properly cited, the use is non-commercial and no modifications or adaptations are made.
© 2024 The Author(s). *Ophthalmic and Physiological Optics* published by John Wiley & Sons Ltd on behalf of College of Optometrists.

Ophthalmic Physiol Opt. 2025;45:437–449. wileyonlinelibrary.com/journal/opo | 437

Figura 6.7. Detalle de la primera página del artículo publicado en *Ophthalmic and Physiological Optics*.

Desarrollo del prototipo del asistente virtual en atención visual primaria

*Development of the prototype of
the virtual assistant in primary eye
care*



7.1. Introducción

La salud visual y ocular es esencial para el bienestar general y tiene un impacto directo en la calidad de vida. El aumento de las demandas visuales, junto con el envejecimiento de la población, hace que aumenten los problemas visuales y trastornos visuo-oculomotores, lo que pone de relieve la importancia del diagnóstico temprano para minimizar el impacto de estas afecciones en la visión y/o calidad de vida de los pacientes.²⁴² Sin embargo, la escasez de especialistas, especialmente en áreas remotas o la sobrecarga de los sistemas de salud dificultan esta detección precoz, resultando frecuentemente en diagnósticos tardíos.²⁴⁴ Por ello, es crucial implementar estrategias eficaces que amplíen el acceso a cuidados visuales y ofrezcan apoyo oportuno en la toma de decisiones clínicas, especialmente en el nivel de atención primaria.¹⁷

Los avances tecnológicos han mostrado gran potencial para superar los desafíos actuales de la atención ocular.^{17,28,248} Herramientas como los asistentes virtuales basados en inteligencia artificial (IA) se proponen como soluciones prometedoras para apoyar a los profesionales de la salud visual, integrando datos clínicos y ofreciendo recomendaciones en tiempo real.²⁸ Estos asistentes están diseñados para simular interacciones humanas, y pueden apoyar en el cribado de afecciones o enfermedades oculares y en la toma de decisiones clínicas, implementándose con diferentes interfaces como chat o

voz.^{249,250} También permiten ofrecer información personalizada basada en los datos del paciente y directrices clínicas, promoviendo mayor eficiencia y precisión en el cuidado de la salud.²⁵¹

En el ámbito concreto de la salud visual, estos sistemas presentan beneficios tanto para los pacientes, ofreciendo una forma conveniente de monitorizar su salud y recibir orientación rápida y accesible sobre los cuidados necesarios, como para los profesionales, ayudando a reducir la carga administrativa o permitiendo un mayor enfoque en los aspectos críticos de la atención clínica.³⁷ Además, cuando se integran con tecnologías de IA, estos sistemas pueden ayudar en el cribado, diagnóstico preliminar y en la personalización de tratamientos, promoviendo un manejo más eficiente de las disfunciones visuales y oculares.^{252,253}

Este capítulo tiene como objetivo desarrollar una aplicación (APP) en formato de asistente virtual (AsV) que integre los modelos de IA desarrollados en esta Tesis Doctoral (Capítulo 6) para su aplicación en atención visual primaria (AVP), con el propósito de facilitar, de manera sencilla y accesible, el uso práctico de la tecnología en entornos clínicos y/o educativos.



7.2. Material y Método

Para el desarrollo del AsV se llevaron a cabo cuatro etapas, adaptadas del *software life cycle*²⁵⁴ (ciclo de vida del *software*), presentadas en la Figura 7.1 y descritas a continuación.

A) Planificación y Estructuración: En esta etapa se definieron las funcionalidades esenciales, incluyendo la estructuración del flujo de datos de la APP, se definió la arquitectura general del sistema, y se identificaron los módulos principales. También se detallaron los procesos involucrados y los componentes necesarios para la implementación del AsV.

B) Diseño y Prototipado: Esta fase se adaptó del *UI design life cycle*²⁵⁵ (ciclo de vida del diseño de interfaces) centrándose en el diseño inicial de las interfaces, incluyendo la creación de pantallas, flujos de navegación, elementos de interacción y experiencias del usuario. El objetivo principal fue garantizar la usabilidad y accesibilidad de la APP para todos los usuarios, cumpliendo con estándares de diseño intuitivo y eficaz.

C) Desarrollo e Integración: En esta etapa, se llevó a cabo la codificación de todas las funcionalidades planificadas en las etapas previas. Para las tareas del lado del servidor, se utilizó ASP.NET - Visual Basic (Microsoft, EE.UU., learn.microsoft.com/dotnet/visual-basic), mientras que para el lado del cliente se empleó JavaScript (jQuery)

(OpenJS Foundation, EE. UU., jquery.com/). Además, se utilizó Python (3.9.7) (Python Software Foundation, EE.UU., python.org) junto con el framework Flask (3.1.0) (Pallets Projects, EE.UU., flask.palletsprojects.com/) para la integración de los modelos de IA generados en Capítulo 6.

D) Pruebas Piloto: La APP fue alojada en Locaweb (Locaweb Servicios de Internet S/A, Brasil, locaweb.com.br/) con protección SSL (Protocolo de Capa de Conexión Segura), lo que garantiza un acceso seguro y encriptado para los usuarios. Se realizaron pruebas internas para asegurar la correcta implementación de todas las funcionalidades previstas. Además, se llevaron a cabo pruebas en diferentes dispositivos y tamaños de pantalla, así como pruebas de integración con los modelos de IA alojados en Google Cloud (Google LLC, EE.UU., cloud.google.com/). Por último, se realizaron ajustes para garantizar la estabilidad y la accesibilidad del sistema, culminando en la publicación de la primera versión.




Figura 7.1. Resumen esquemático del flujo de la metodología aplicada.



7.3. Resultados y discusión

La etapa de *Planificación y Estructuración* (Figura 7.2) dio lugar a una APP con arquitectura híbrida que combina la tecnología cliente-servidor y la computación en la nube. La tecnología cliente-servidor permite que las tareas y recursos se distribuyan entre los dispositivos de los usuarios (clientes) y un servidor central que procesa las solicitudes, permitiendo una comunicación eficiente y directa entre ambos.²⁵⁶ Por otro lado, la computación en la nube emplea servidores remotos para almacenar datos y realizar procesos complejos.²⁵⁷ En este sistema, la interacción con la APP es gestionada por el cliente o el servidor de manera directa, mientras que los modelos de IA, debido a sus altos requerimientos de procesamiento, se ejecutan en Google Cloud, una plataforma de servicios en la nube que ofrece escalabilidad, alta disponibilidad y capacidades avanzadas de procesamiento.²⁵⁸

En cuanto a la interfaz general, el sistema se estructuró en tres módulos (entendidos como conjuntos de elementos con una función común): “**Encontrar modelo**”, diseñado para localizar el modelo de IA disponible; “**Panel de consulta**”, destinado a interactuar con el modelo seleccionado; y “**Resultado**”, para presentar las respuestas generadas por el modelo consultado. Esta estructura modular permite organizar las funcionalidades de manera clara, facilitando la interacción del usuario con el sistema.




Figura 7.2. Esquema general de planificación y estructuración del asistente virtual en atención visual primaria.

Encontrar modelo: Teniendo en cuenta una secuencia lógica de uso, este es el primer módulo de interacción con el usuario y cuenta con dos componentes: *Chatbot* y *Menú*. Su función principal es facilitar al usuario la identificación de la solución a su problema, es decir, localizar los modelos de IA entrenados que puedan responder a su consulta. Para un AsV, la forma más predecible de realizar esta tarea es mediante

un *chatbot* elemental, que, a través de palabras clave proporcionadas por el usuario, localiza las opciones de modelos disponibles. Dado que el sistema no está enfocado, en esta fase, en el desarrollo de un *chatbot* avanzado con respuestas basadas en modelos de lenguaje de gran escala (LLM) como *ChatGPT*^{259,260} u otras herramientas de IA similares, se optó por incluir, como alternativa, un *Menú* que lista las opciones de modelos disponibles, simplificando este proceso. Aunque con pocos modelos implementados esta función puede parecer de escasa relevancia, a medida que aumente la oferta de modelos entrenados, este módulo será más relevante y esencial para el uso eficiente del AsV.

Panel de consulta: Este módulo se encarga de interactuar con el modelo seleccionado. Además de los mensajes generales de comunicación del asistente (informando y solicitando la entrada de datos), cuenta con un único componente: *panel de signos y síntomas*, que corresponde a una lista de entradas directamente relacionadas con el modelo seleccionado. Es decir, cada modelo tendrá un conjunto específico de datos que pueden ser introducidos por el usuario. Este módulo está vinculado a procesos internos, definidos como conjuntos de funciones específicas con un propósito común, fundamentales para los objetivos del asistente. Estos procesos han sido denominados 'Modulación' e 'Integración', los cuales se explican a continuación.

Modulación: Uno de los procedimientos fundamentales de la APP es este proceso de modulación, que se encarga de adaptar la nomenclatura clínica utilizada en las ciencias de la visión al formato requerido por los modelos de IA, y viceversa. Los modelos de IA son entrenados con codificaciones específicas, como valores binarios, nominales o normalizados, que difieren significativamente del lenguaje

natural empleado en la documentación clínica. Por ejemplo, la agudeza visual puede estar registrada en diversos formatos en los historiales clínicos. La modulación realiza esta integración semántica^{261,262} de forma dinámica e invisible para el usuario, permitiendo la inclusión de signos, síntomas y resultados de exámenes de forma sencilla y natural, sin que el usuario deba preocuparse por la conversión técnica de los datos (binarios, normalizados, etc.). Además, este proceso complementa los datos ingresados con valores predeterminados o promedios en caso de que algunas informaciones necesarias para el modelo no sean proporcionadas, asegurando así la funcionalidad del sistema.

Integración: Este es el proceso que conecta, de manera efectiva, los datos predictivos (entradas) proporcionados por los usuarios con los modelos de IA entrenados (Capítulo 6), los cuales están alojados y ejecutados en Google Cloud. Este proceso interno gestiona la API (Interfaz de Programación de Aplicaciones),²⁵ organizando y dando formato tanto a las informaciones de entrada como a las de salida. Es decir, no solo envía los datos al modelo, sino que también recibe las respuestas de las predicciones, integrándolas al asistente para que puedan ser presentadas de manera adecuada al usuario.

Resultado: Este módulo se encarga de recibir el retorno del proceso de integración con el modelo alojado en la nube y, de manera similar, requiere funciones de modulación para presentar las predicciones al usuario de forma comprensible. Cuenta con un componente opcional que permite la visualización de *estadísticas* relacionadas con las predicciones, como la probabilidad de cada clase de resultado, así como los campos de entrada enviados (parámetros

predictivos) y las métricas de rendimiento del modelo utilizado. Este enfoque facilita al usuario interpretar tanto los resultados como la calidad del modelo aplicado.

En la etapa de *Diseño y Prototipado*, la APP fue diseñada con el objetivo de ofrecer una interacción lúdica y amigable, basada en principios clave: *diseño web responsivo* (del inglés Responsive Web Design o RWD)²⁶³ que permite el acceso desde navegadores en diversos dispositivos; *pocas pantallas* que facilitan la navegación; *soporte multilingüe* en tres idiomas (español, inglés y portugués de Brasil); un *enfoque en funcionalidades esenciales* para la versión inicial; y una *ejecución optimizada* que prioriza la integración y la interacción eficiente de los modelos de IA dirigidos a profesionales de la salud visual. Estos principios guiaron todo el diseño de la solución tecnológica, enfocándose en la eficiencia, operatividad y accesibilidad.²⁶⁴

Los elementos principales de interfaz (paneles, textos, botones y formulario) se segmentaron en cuatro grupos funcionales y fueron propuestos con fines de diseño del asistente (Tabla 7.1). Los *Controles Generales* permiten acceder a menús desplegables y expandir secciones de información sobre la APP (acerca de autores, versión), así como cambiar el idioma. Por su parte, las *Unidades de Comunicación* se encargan de presentar mensajes, instrucciones y resultados, asegurando que el usuario puede comprender e interactuar fácilmente con el AsV. Los *Controles de Navegación* cumplen la función de guiar al usuario hacia los módulos fundamentales de la APP, promoviendo una interacción lógica con el flujo del sistema. Finalmente, las *Unidades de Interacción* se enfocan en ejecutar tareas clave, como la introducción de datos, la selección de opciones y la ejecución de predicciones.

Tabla 7.1. Elementos principales de interfaz, segmentados por grupos funcionales, módulos (corchetes), componentes (cursiva) y procesos (subrayados) relacionados.

	Elementos de interfaz <i>{tipo}</i>	Función general	[Módulos], <i>Componentes</i> y <u>Procesos</u> relacionados
Controles generales	Menú de soporte <i>{ Botón / Panel }</i>	Abrir panel con información sobre la aplicación y idioma	Interfaz general
	Historial de mensajes <i>{ Botón / Panel }</i>	Expandir la visualización del historial reciente del <i>chatbot</i>	
Unidades de comunicación	Mensaje del asistente y usuario <i>{ Texto }</i>		Interfaz general
	Entrada de datos (signos/síntomas) <i>{ Texto }</i>	Interacción (<i>chatbot</i>): asistente - usuario	[Panel de consulta] <i>Panel de signos y/o síntomas</i> <u>Modulación</u>
	Salida (resultado de la predicción) <i>{ Texto }</i>		Interfaz general [Resultado] <u>Modulación</u>
Controles de navegación	Menú de modelos <i>{ Botón / Panel }</i>	Abrir panel de selección de modelos IA disponibles	[Encontrar modelo] <i>Menú</i>
	Menú para añadir signos y síntomas <i>{ Botón / Panel }</i>	Abrir panel para la inserción de entradas para los modelos	[Panel de signos y/o síntomas] <u>Modulación</u>
Unidades de interacción	Entrada de datos del usuario en <i>chatbot</i> <i>{ Botón / Formulario }</i>	Interacción del usuario (entrada del <i>chatbot</i>) y procesamiento de la respuesta	Interfaz general [Encontrar modelo] <i>Chatbot</i>
	Selección del modelo <i>{ Botón }</i>	Abrir panel de consulta del modelo seleccionado	Interfaz general [Encontrar modelo] <i>Menú</i>
	Ejecución del modelo <i>{ Botón }</i>	Ejecutar la integración con el modelo IA y recibir la respuesta	[Panel de consulta] <u>Integración</u>
	Estadística de los resultados <i>{ Botón / Panel }</i>	Abrir las estadísticas relacionadas con la consulta	[Resultado] <i>Estadística</i> <u>Modulación</u>

Aunque el sistema debe ser adaptable a cualquier pantalla, el diseño fue concebido considerando el formato de dispositivo más popular (*smartphone*), siguiendo el principio de “*mobile first*”¹⁹ (Figura 7.3).




Figura 7.3. Wireframes del proyecto del asistente, presentando 4 momentos de interacción, así como los puntos clave de desarrollo numerados: Controles generales (azul), como el menú de soporte (1) y el histórico de conversación (13); Unidades de comunicación (rosa), como el mensaje del asistente (2, 6, 8), el mensaje del usuario (5), las entradas ingresadas (10) y la salida de la consulta (14); Controles de navegación (naranja), como el botón del menú de modelos (3) y el menú para añadir signos y síntomas (11); y Unidades de interacción (verde), como la entrada de datos vía *chatbot* (4), la selección (7, 9), la ejecución del procedimiento de predicción (12) y la visualización estadística de los resultados (15).

De este modo, se propuso un *wireframe*²⁶⁵ (bosquejo de interfaz) inspirado en un *chatbot*,^{266,267} compuesto por 15 elementos de interfaz distribuidos en cuatro momentos de interacción, representados como “pantallas”. No obstante, el diseño corresponde a una única página dinámica, donde los módulos se despliegan progresivamente según la

interacción, sin necesidad de recargar ni navegar entre páginas, donde una estructura de página única (SPA - *Single Page Applications*) busca dar fluidez en la navegación y una experiencia continua.²⁶⁸ Una versión prototipada sin integración de modelos fue presentada en la VI Jornada de Investigadores Predoctorales de la UVA en Ciencias de la Visión (2022), obteniendo el premio a la mejor presentación.

En la fase de *Desarrollo e Integración* se implementó un sistema *web-based*,²⁶³ es decir, una solución accesible a través de un navegador de internet. Para este fin, se desarrolló una propuesta responsiva (adaptable a diferentes tamaños de pantalla), de acceso libre, denominada **VICHI** (*Vision Care Helper Intelligence*), disponible en tres idiomas (inglés, español y portugués-Brasil). La herramienta está integrada con Google Cloud, que gestiona los modelos de IA desarrollados en Capítulo 6, siendo orientada a profesionales de la visión, con el objetivo de facilitar la consulta de modelos de IA diseñados específicamente para apoyar la toma de decisiones en la AVP.^{30,269}

La Figura 7.4 presenta la interfaz general y las interacciones iniciales del asistente y el módulo para **“Encontrar Modelo”**. En la primera interacción (Figura 7.4-A), el asistente da la bienvenida al usuario. Es importante señalar que, siempre en el primer acceso, se solicitará la autorización para el uso de cookies, pequeños archivos que almacenan información del usuario, cumpliendo con los reglamentos de protección de privacidad.²⁷⁰ En este caso, además de las cookies esenciales relacionadas con la navegabilidad, solo se solicitan datos adicionales de localización, gestionados por Google. Estos datos no tienen una función directa con la APP y se utilizan exclusivamente para fines estadísticos relacionados con los accesos.

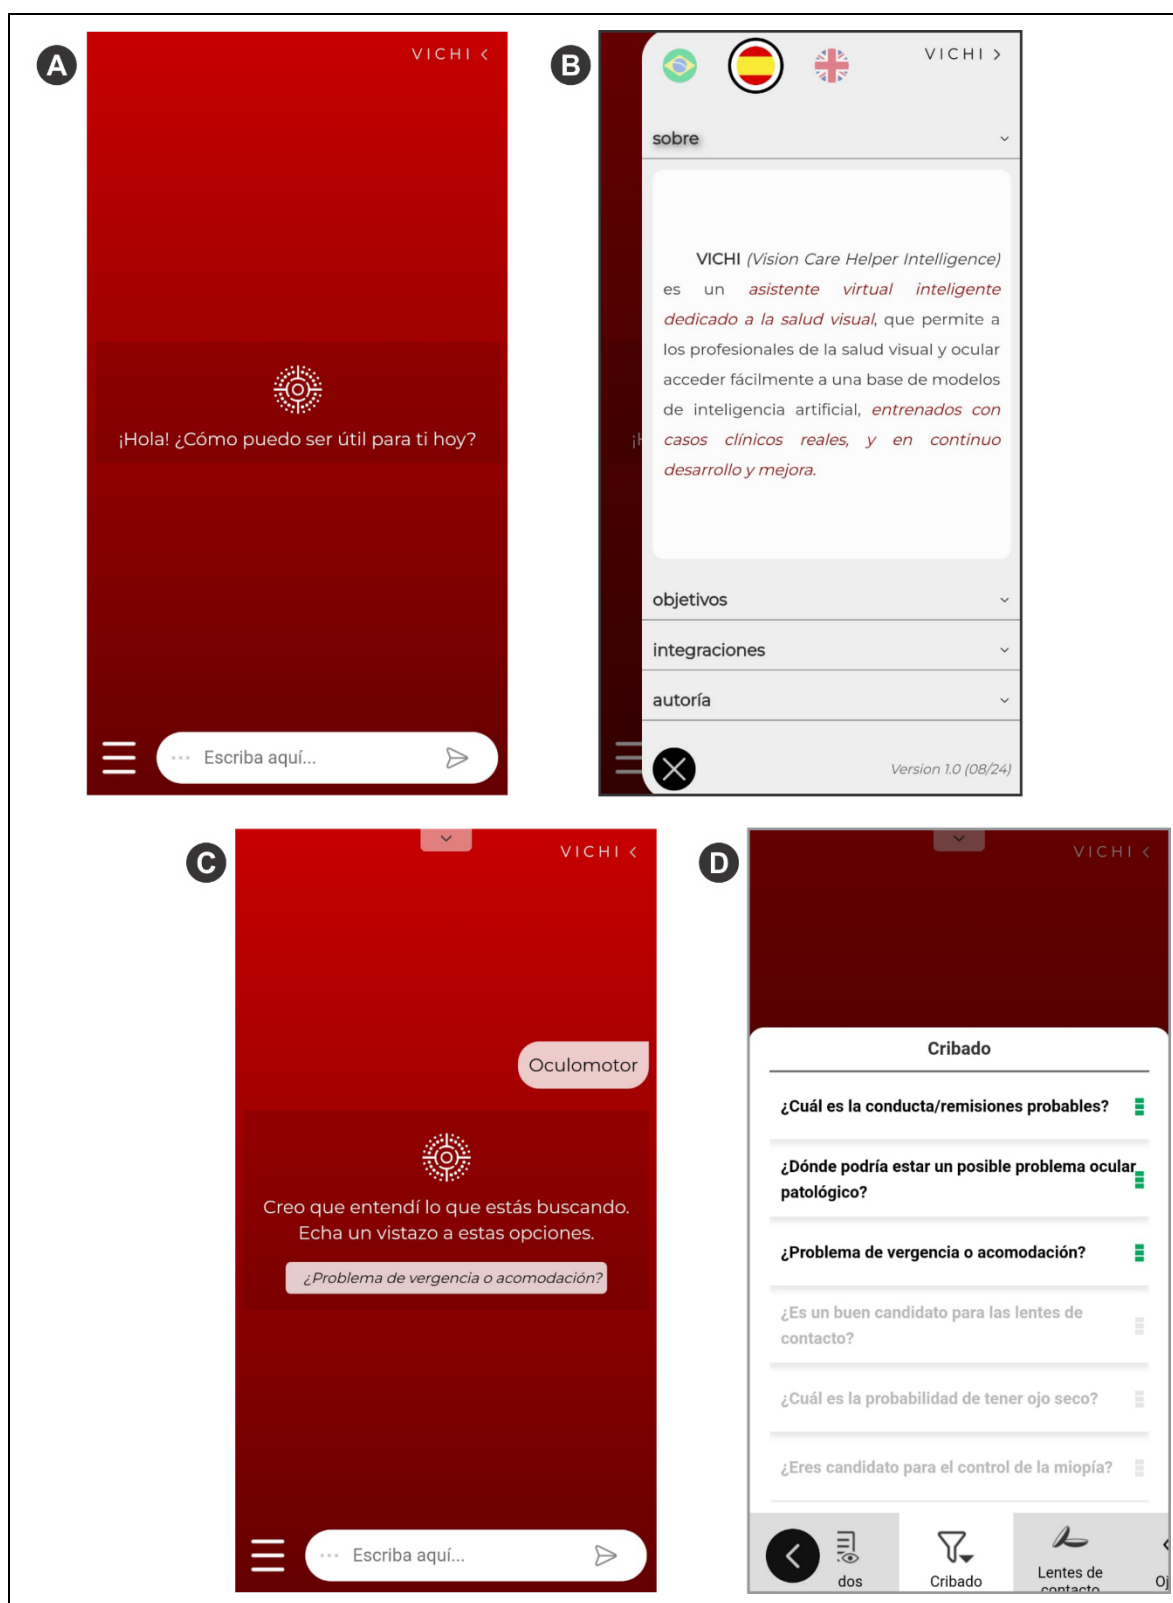


Figura 7.4. Interfaz general y módulo 'Encontrar Modelo'. **A:** Bienvenida y formulario para interacción inicial del asistente. **B:** Panel informativo y de idioma. **C:** Ejemplo de *chatbot* simple con respuesta basada en palabras clave ingresadas por el usuario. **D:** Menú con lista de modelos disponibles para consulta y selección.

En la Figura 7.4-B se muestra un panel móvil que contiene información como descripción, objetivos, autores, integración y versión, además de la opción para cambiar el idioma. Por defecto, se carga el correspondiente al navegador del usuario, manteniéndose activo durante toda la interacción con la APP. Si no está disponible, se utilizará el inglés como predeterminado. Al seleccionar un nuevo lenguaje en el menú, el sistema recargará la APP utilizando la biblioteca correspondiente al idioma.

Las Figuras 7.4-C y 7.4-D ilustran los componentes del *Chatbot* y del *Menú* de este módulo. En la Figura 7.4-C, el usuario puede interactuar con el asistente ingresando texto en el formulario. El sistema analiza las palabras clave para identificar si hay un modelo disponible que sea compatible, sugiriéndolo al usuario. En caso de que no encuentre coincidencias o no comprenda la solicitud, se enviará un mensaje de orientación al usuario. Por otro lado, en la Figura 7.4-D se presenta otra opción para localizar modelos disponibles: el acceso al panel móvil (menú), donde se listan los modelos consultables.

En el desarrollo de este módulo destaca cómo funcionalidad básica que permite facilitar la localización de herramientas fundamentales. Este enfoque resulta especialmente relevante en entornos clínicos, donde la rapidez y la eficiencia son factores esenciales.²⁷¹ La inclusión de un *chatbot* (aunque aún rudimentario) y un menú con opciones complementarias sugiere que tanto usuarios con experiencia en tecnología como aquellos con conocimientos más limitados puedan interactuar fácilmente con el sistema desarrollado.

La Figura 7.5 ilustra el módulo dedicado al “**Panel de consulta**”. Una vez seleccionado el modelo, el panel correspondiente se despliega

dinámicamente. El asistente solicita la introducción de las entradas específicas para el caso. De manera predeterminada, se presentan las cuatro características más relevantes (Figura 7.5-A), las cuales son obligatorias, es decir, representan la cantidad mínima de variables predictoras necesarias para realizar una consulta. Los demás campos, si no se completan, serán asignados automáticamente por el asistente con un valor predeterminado: el valor medio para variables numéricas y el valor más frecuente para variables nominales o binarias.

El proceso de modulación se ejemplifica en la Figura 7.5-B. De este modo, una vez seleccionada la información que se desea proporcionar, las opciones se presentan visualmente mediante un control deslizante. Este diseño permite a los profesionales de la visión desplazarse entre las opciones disponibles de manera intuitiva y seleccionar la más adecuada. En el ejemplo, la agudeza visual se muestra en el formato de Snellen, aunque también es posible elegir otros tipos de notación para esta variable. El asistente, de manera interna, se encarga de convertir los datos al formato en el que fueron entrenados los modelos de IA, mientras que la información se presenta en escalas o notaciones conocidas por los usuarios (profesionales de la visión).

Además de los datos mínimos de entrada, el componente del panel de signos y síntomas complementa el módulo, permitiendo la inclusión de diferentes características con las que el modelo ha sido entrenado (Figura 7.5-C). Se ofrece un filtro que facilita la localización en el campo predictor mediante la clasificación por tipo de información (Información General, Anamnesis, Agudeza Visual, Exploración Ocular y Motor).

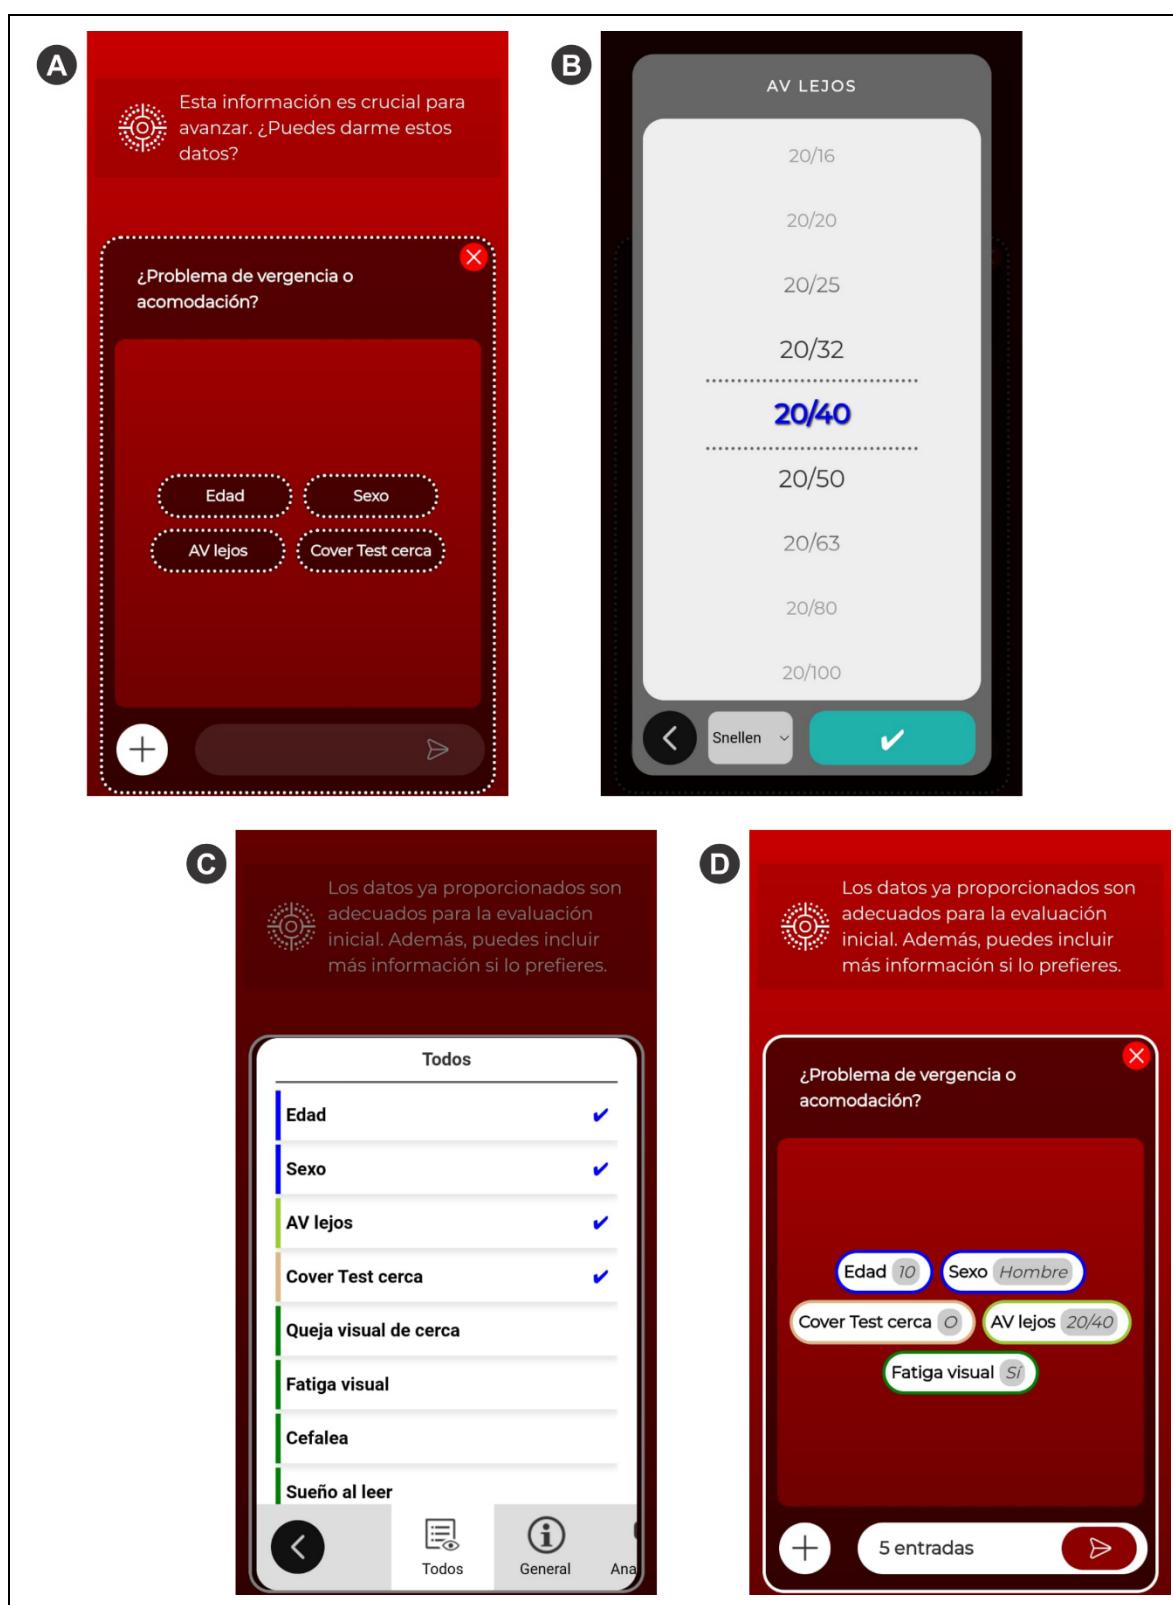


Figura 7.5. Interacciones en el módulo 'Panel de consulta'. **A:** Panel inicial y datos mínimos requeridos. **B:** Proceso de modulación de entradas de datos. **C:** Componente del panel para añadir más características predictoras. **D:** Presentación visual de las entradas proporcionadas por el usuario.

De igual forma, la modulación se aplica a todas estas características, no siendo posible introducir las entradas de manera manual, lo que facilita la interacción y previene errores en la integración con los modelos al realizar la consulta de predicción. Todas las entradas proporcionadas por el usuario se presentan con contornos de colores que representan el tipo de características y pueden ser editadas si el usuario lo desea. Existe un botón permanente que permite cancelar la consulta en cualquier momento, así como una opción (botón) de ejecución de la predicción, que se habilita únicamente cuando se ha cumplido el número mínimo de características requeridas (Figura 7.5-D).

El módulo “*Panel de consulta*” subraya la importancia de un diseño adaptado a los profesionales de la salud visual, garantizando que el sistema sea accesible y fácil de usar incluso en entornos con limitaciones técnicas, mediante métodos que optimicen la interpretabilidad de las interacciones con la IA. A través del proceso de modulación implementado, se busca garantizar la compatibilidad entre los datos y los modelos entrenados, reducir los errores asociados al ingreso de datos y permitir que los profesionales se concentren en la interpretación de los resultados y en la actuación clínica.²⁷² Asimismo, este enfoque podría constituir una referencia importante para futuras aplicaciones en el ámbito de la salud que busquen integrar modelos predictivos similares al desarrollado.

La Figura 7.6 ejemplifica el módulo de “**Resultado**”, representando la respuesta obtenida tras la consulta al modelo de IA, con los parámetros de entrada correspondientes a los signos y síntomas proporcionados por el usuario en el módulo de consulta. La Figura 7.6-

A muestra un ícono animado de espera/procesamiento, que representa el proceso de integración en ejecución. Es decir, las informaciones de entrada están siendo enviadas al modelo alojado en la nube (Google Cloud). Este procedimiento puede tener un tiempo de procesamiento más lento, especialmente durante su primera ejecución, debido a que se está estableciendo la conexión con el sistema externo.

Una vez establecida la conexión con el modelo en la nube, el resultado de la predicción es modulado y presentado al usuario de forma textual (Figura 7.6-B). El resultado corresponde a la opción con mayor probabilidad entre las diferentes salidas posibles. La coloración del texto asociado a esta probabilidad, en comparación con las otras opciones, indica si el valor es relevante (color verde) o si presenta poca diferencia respecto a las demás opciones (color amarillo). Al hacer clic en la respuesta, se despliega el componente de estadísticas relacionadas con el modelo consultado (Figura 7.6-C), donde se pueden visualizar las probabilidades de las otras opciones de salida, revisar las entradas proporcionadas y consultar las métricas de desempeño del modelo. Esta información es útil para que el profesional disponga de elementos adicionales para tomar decisiones fundamentadas.

La Figura 7.6-D representa el reinicio del flujo de uso, donde el asistente retorna al punto inicial y la consulta realizada queda listada en el historial del asistente. Es importante destacar que las consultas permanecen visibles hasta el siguiente reinicio del asistente (reapertura), momento en el cual se restablece el sistema y el historial se elimina. Esto se debe a que, en la versión inicial, no se ha diseñado ningún sistema de almacenamiento permanente de datos.

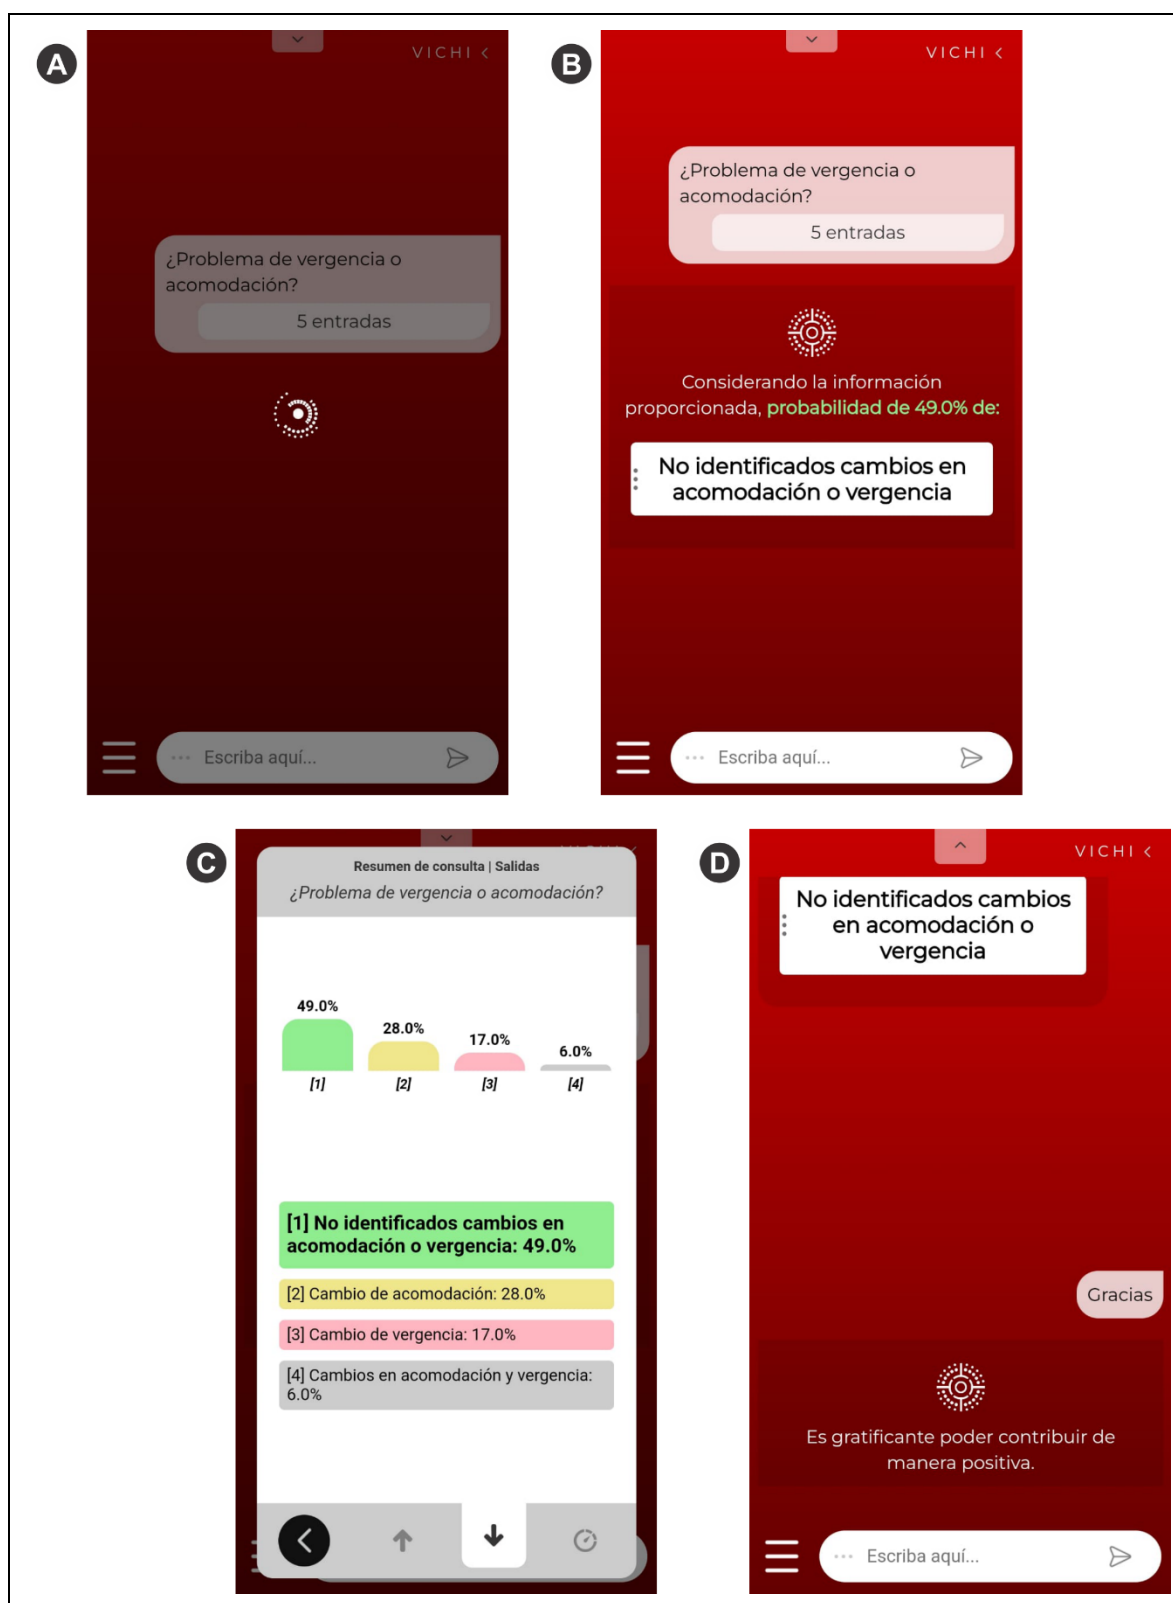


Figura 7.6. Interacciones en el módulo ‘Resultado’. **A:** Procesamiento de la integración con el servicio en la nube (modelos). **B:** Presentación del resultado de la predicción. **C:** Componente con información estadística del modelo ejecutado. **D:** Ejemplo de *chatbot* que marca la finalización del ciclo de consulta.

La integración del AsV con Google Cloud proporciona una escalabilidad y capacidad de procesamiento que serían difíciles de alcanzar con infraestructura local.²⁷³ Sin embargo, esta dependencia también puede presentar desafíos, como la latencia observada durante la primera ejecución de los modelos, lo que demuestra la necesidad de mejoras y soluciones futuras para reducir posibles interrupciones que podrían impactar en la usabilidad. El componente de estadísticas relacionadas con los modelos de IA representa un avance significativo para promover la transparencia en el uso de estas herramientas.²⁷⁴ Al proporcionar detalles sobre las probabilidades de las predicciones y las métricas de rendimiento del modelo, los profesionales de la salud visual pueden tomar decisiones más fundamentadas, aumentando así la confianza en las tecnologías basadas en IA.^{275,276}

Por último, para las primeras pruebas, la APP fue transferida a un servicio de alojamiento remoto (<https://www.visioncare.digital/vichi>), donde se verificó el correcto funcionamiento de todos los elementos y componentes, así como las conexiones con los modelos en la nube. También se evaluó la adaptabilidad a diferentes dispositivos con tamaños de pantalla variados, tanto en *Desktops*, ordenadores de escritorio (Figura 7.7-A), como en *tablets* y *smartphones* (Figura 7.7-B). Se realizaron pequeños ajustes y correcciones identificados durante las pruebas, lo que permitió lanzar la primera versión (1.0) en agosto de 2024.

Los asistentes virtuales basados en IA son sistemas diseñados para simular interacciones humanas, ofreciendo apoyo e información en tiempo real a través de interfaces de texto o voz. Su uso se ha extendido ampliamente en el ámbito de la salud, abarcando funciones como la

programación de citas, detección de síntomas, manejo de enfermedades y selección de tratamientos basados en evidencia clínica.³⁷ Estos sistemas han demostrado mejorar la adherencia de los pacientes a los tratamientos, promover estilos de vida saludables y proporcionar apoyo continuo y personalizado.^{36,249,253} Para los profesionales, los asistentes virtuales contribuyen a reducir la carga de trabajo administrativo al automatizar tareas rutinarias, permitiéndoles centrar su atención en aspectos críticos del cuidado del paciente,^{37,249–253} mientras que para los estudiantes, pueden tener gran potencial, especialmente en la práctica preclínica, pudiendo apoyar en la evaluación clínica y el desarrollo de habilidades analíticas antes de interactuar con pacientes, mejorando su preparación y aumentando la seguridad para los pacientes y/o voluntarios.^{277–279}

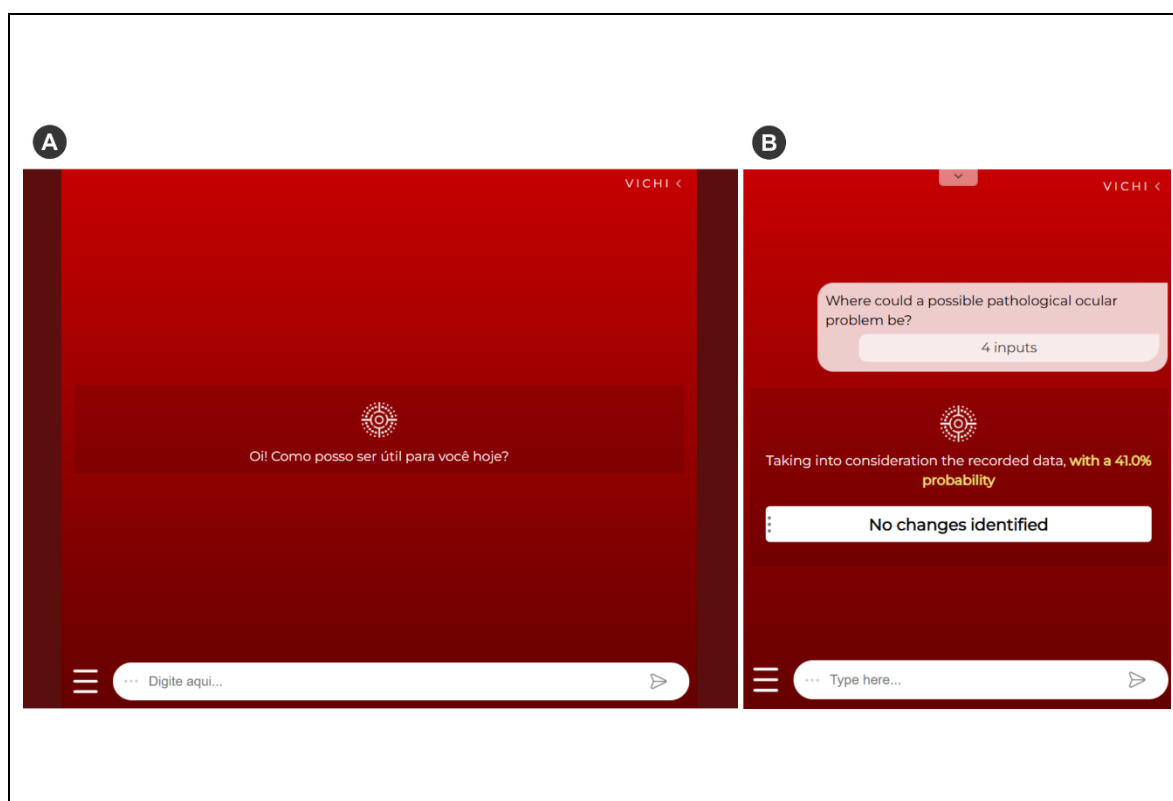


Figura 7.7. Prueba de responsividad (del inglés *Responsive Test Tool*) del asistente VICHÍ. **A:** Ejecutado en un dispositivo de escritorio (*desktop*). **B:** Ejecutado en un dispositivo *tablet*.y *smartphones*.

Sin embargo, a pesar de los beneficios, el acceso a estos modelos de IA sigue siendo limitado en la práctica clínica diaria para muchos profesionales, particularmente en el ámbito de la Optometría.^{280,281} Aunque se cuenta con un campo altamente desarrollado en cuanto a la asociación de tecnologías móviles con el apoyo de IA,^{29,30,282} aún no existen asistentes virtuales dedicados y diseñados específicamente para la AVP, lo que subraya la necesidad de innovaciones que acerquen el uso de la IA a aplicaciones prácticas en este campo. No obstante, estos asistentes nunca deben ser percibidos como sustitutos del profesional, ya que el cuidado personalizado y el interés específico del paciente deben ser la prioridad en los cuidados de la salud visual.

7.4. Difusión

El asistente **VICHI** es de acceso abierto a través del enlace a continuación o mediante el código *QRcode*.

VICHI (Vision Care Helper Intelligence)

<https://www.visioncare.digital/vichi>



Resultados preliminares, incluyendo la demostración del prototipo no funcional del AsV, fueron presentados en la VI Jornada de Investigadores Predoctorales de la UVA en Ciencias de la Visión (2022).

VI Jornada de Investigadores Predoctorales de la UVA en Ciencias de la Visión. Premio a la mejor comunicación. **Desarrollo y validación de un servicio de asistente virtual inteligente para apoyar la decisión clínica en atención visual primaria.** Stuermer L. al 30 de junio de 2022.



También se incluyó el AsV como parte de los resultados publicados tanto en el artículo en la revista *Ophthalmic and Physiological Optics*, como en la comunicación en el congreso OPTOM 2024, que se han destacado en la difusión del Capítulo 6, (previamente mencionados).

Validación de modelos de inteligencia artificial para apoyar la toma de decisiones en salud visual y ocular

*Validation of artificial intelligence
models to support decision making
in eye and vision health*



8.1. Introducción

Los avances tecnológicos de las últimas décadas han impulsado significativamente el uso de herramientas digitales e inteligencia artificial (IA) en diversas áreas de la salud, incluida la salud visual y ocular,^{162,283} como se explora en el Capítulo 3. En este contexto, destaca especialmente el potencial de la IA para respaldar la toma de decisiones clínicas, proporcionando a los profesionales recursos adicionales que pueden mejorar la precisión diagnóstica y optimizar las conductas clínicas.¹⁷ La integración de tecnologías respaldadas por modelos de IA, como los asistentes virtuales, como el desarrollado en el Capítulo 8, en el ámbito profesional promete contribuir no solo a una mayor eficacia clínica, sino también a una mejora general en la atención al paciente.^{284,285}

Los profesionales del área de la salud visual suelen enfrentarse al desafío de realizar diagnósticos y decidir derivaciones terapéuticas basándose en informaciones clínicas que puede ser limitadas o de difícil interpretación.²⁸⁶ Este escenario puede derivar en decisiones clínicas incorrectas o tardías, que puede comprometer tanto el resultado terapéutico como la calidad de la atención, que sugieren una oportunidad para el desarrollo y uso de nuevas herramientas auxiliares que apoyen en la toma de decisiones clínicas.²⁸⁷

Por otro lado, el uso de la IA en salud presenta limitaciones que van desde la dificultad de extrapolar modelos a la realidad hasta cuestiones éticas y de confianza por parte de los profesionales, sin olvidar aspectos legales relacionados con la responsabilidad de las decisiones clínicas. Un desafío clave es la capacidad de generalización de los algoritmos, que pueden no ser igualmente precisos en distintos contextos clínicos.²⁸⁸ Además, su desarrollo plantea dilemas sobre la privacidad de datos, transparencia y la necesidad de enfoques centrados en el ser humano para garantizar que la IA actúe como un apoyo en la toma de decisiones clínicas, en lugar de reemplazar el juicio profesional.²⁸⁹ Asimismo, es fundamental considerar la percepción que tienen los profesionales de la salud respecto al nivel de confianza, interacción y aceptación del uso en la práctica clínica, de estas tecnologías para garantizar su integración de manera complementaria al juicio del profesional.^{290,291}

En este contexto, resulta interesante profundizar en la comprensión de cómo el uso de esta tecnología puede impactar e interactuar en la práctica de los profesionales de la salud visual. De este modo, en este capítulo se analiza la potencial influencia en la toma de decisiones clínicas de un asistente virtual (AsV) basado en modelos de IA dedicado a la atención visual primaria, tal como se presenta en el Capítulo 7, además de conocer la opinión y la percepción de los profesionales sobre el uso de la tecnología de IA en el cuidado de la visión.



8.2. Material y Método

Se diseñó un estudio cuantitativo, transversal y comparativo, que fue aprobado por el Comité de Ética de la Investigación con Medicamentos de las Áreas de Salud de Valladolid (*Anexo B*) para conocer la opinión de profesionales de la salud mediante un cuestionario estructurado, online y anónimo elaborado en la plataforma Google Forms e incorporado en la página web del AsV diseñado en esta Tesis Doctoral (<https://www.visioncare.digital.digital/vichi/validation>), disponible en tres idiomas (portugués, español e inglés). Se invitó a diferentes asociaciones profesionales de España (Colegios Profesionales de Ópticos Optometristas y Asociación profesional de Ópticos-Optometristas), Portugal (asociaciones profesionales) y Latinoamérica (asociaciones y grupos de Optometristas de Argentina, Brasil, Colombia, Ecuador) a que divulgaran entre sus profesionales el cuestionario on-line, además de publicitarlo entre las redes sociales de los autores, manteniéndose disponible durante los meses de Agosto y Septiembre de 2024. Los profesionales que aceptaron responder el formulario fueron asignados aleatoriamente en dos grupos: Grupo Intervención (GI), en el que se incluyó una intervención específica en la segunda sesión del cuestionario, y Grupo Control (GC), utilizado como referencia comparativa (Figura 8.1).

Diseño del cuestionario

El cuestionario (*Anexo C*) incluyó un total de 16 preguntas, precedido por la aceptación de la participación que exigía dar el consentimiento informado, y se organizó en tres secciones distintas:

Sección I – Perfil: Correspondiente a las preguntas de la 1 a la 5 con el objetivo de caracterizar el perfil del participante, recogiendo información sobre sexo, edad, situación profesional, experiencia y ubicación para verificar los criterios de inclusión y exclusión, además de posibilitar la segmentación de los resultados para el posterior análisis estadístico.

Sección II – Casos clínicos: Se presentaron ocho preguntas (de la 6 a la 13) correspondientes a seis casos clínicos cuatro reales (numerados con las letras A, B, C y D) y dos casos simulados (numerados con las letras E y F) que se complementan con dos preguntas sobre el nivel de confianza en la respuesta (escala de Likert).

Los casos clínicos se distribuyen en dos casos de hipótesis de remisión (A y D), dos casos de hipótesis diagnóstica relacionada con disfunciones oculomotoras (B y E) y dos casos de hipótesis diagnóstica relacionada con problemas patológicos (C y F). El cuestionario proporciona la descripción de unos pocos signos y síntomas clínicos de cada caso para que los participantes indiquen la hipótesis diagnóstica o de remisión que considera más probable entre las alternativas proporcionadas, incluyendo además una opción para omitir la respuesta en caso de no ser su área de especialización o considerar que no disponen de información suficiente.

Adicionalmente, dos preguntas, cada una en la secuencia de los casos E y F, pidieron que los participantes valoraran en una escala Likert-numérica de 1 a 5 el nivel de confianza sobre su respuesta en los respectivos casos simulados.

En esta sección, en la presentación de los casos correspondiente al GI se incluyó la información sobre las predicciones realizadas por el modelo de IA del AsV, presentada con la afirmación: “*Asistente virtual: Un modelo de IA predice una mayor probabilidad de que este caso tenga...*”, seguida del resultado ofrecido por el modelo, sin incluir detalle sobre la probabilidad de acierto del modelo de AsV. Es importante destacar que las respuestas proporcionadas por el AsV fueron correctas (coincidieron con el caso real) en los casos A, B y C, mientras que en el caso D la respuesta fue incorrecta. Por el contrario, en el GC no se incluyó información adicional salvo la descripción del caso clínico.

Los cuatro primeros casos (A, B, C y D) corresponden a casos reales cuyos datos clínicos se han utilizado en el entrenamiento de los modelos del AsV (Capítulo 6). Mientras que los casos E y F son simulados (no existen en la base de datos original). En estos dos casos, además de la respuesta ofrecida por el AsV se informó de la probabilidad del resultado proporcionado por el asistente.

Sección III – Percepción y opinión: Incluyó tres preguntas adicionales, la primera destinada a conocer la opinión de los participantes sobre la utilidad de un AsV en la práctica clínica (pregunta 14), la segunda sobre la percepción de confianza hacia herramientas basadas en IA (pregunta 15) y a tercera (pregunta 16) sobre los sentimientos asociados al uso de la IA, tecnologías digitales y el futuro profesional. Las dos primeras utilizando una escala tipo Likert para

valorar el grado de acuerdo escogiendo entre 5 opciones (desde “totalmente de acuerdo” hasta “totalmente en desacuerdo” en la pregunta 14 o desde “confío totalmente” hasta “Desconfío totalmente” en la pregunta 15), mientras que la pregunta 16 al preguntar por los sentimientos asociados al uso de la IA, tecnologías y futuro profesional, mostraba nueve opciones (cuatro con carácter positivo, cuatro negativo y una neutra) permitiendo seleccionar hasta de tres opciones .

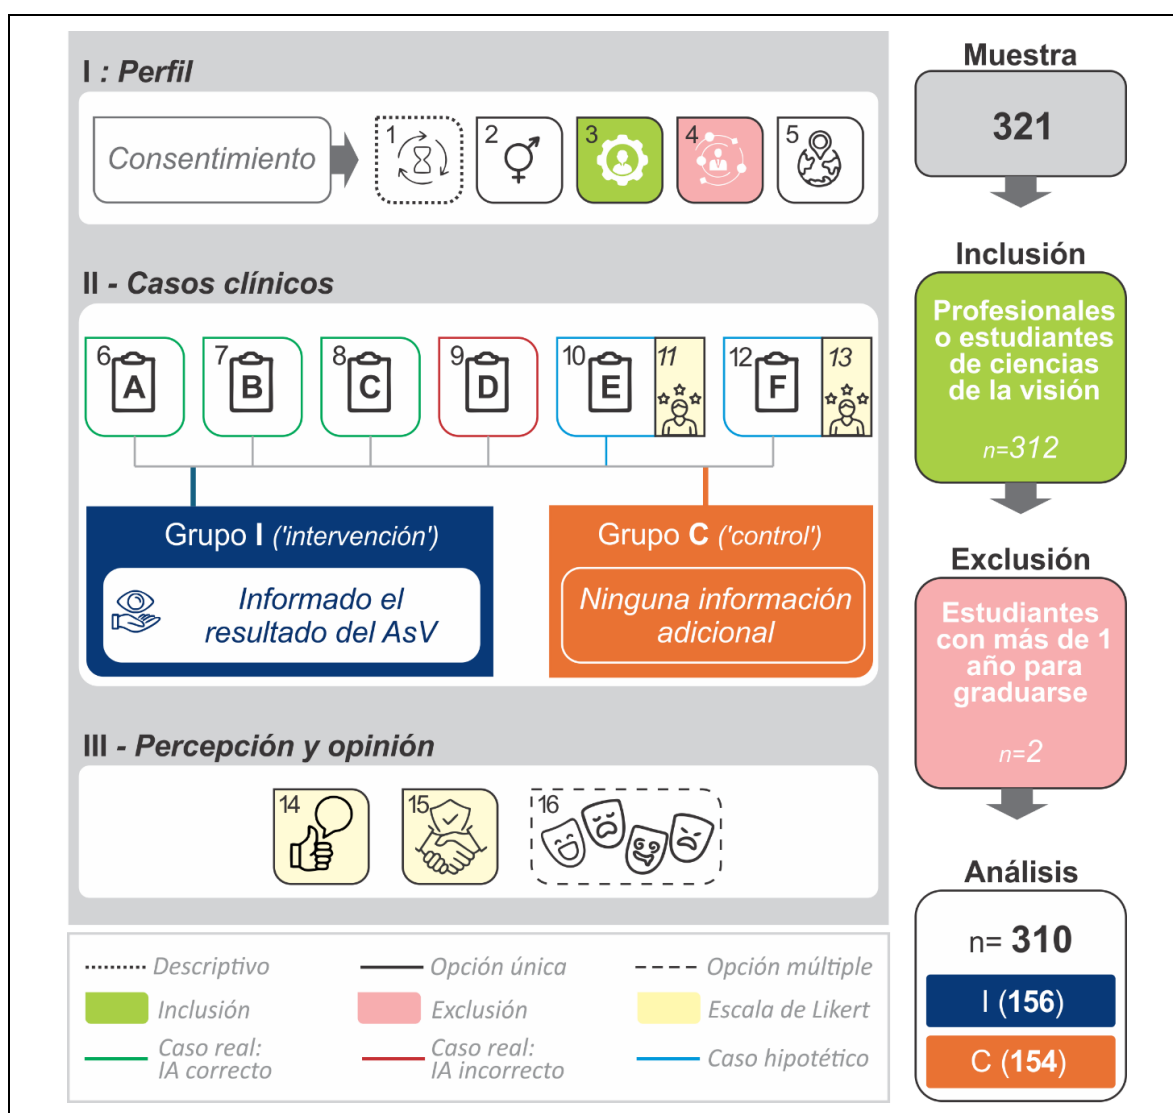


Figura 8.1. Esquema general del diseño del cuestionario (fondo gris – izquierda) con la presentación de las preguntas que conformaron las tres secciones del cuestionario y del resumen de la metodología (derecha) y los resultados de participación. AsV = Asistente Virtual. GI = Grupo intervención, GC = Grupo control.

Procedimiento general

En general, todas las preguntas del cuestionario, excepto la primera (edad), que era descriptiva, y la última (pregunta 16), que permitía respuesta múltiple (hasta tres opciones) fueron preguntas de elección múltiple con una única respuesta en las que los participantes debían elegir una opción entre las mostradas. Asimismo, en todas las preguntas existía la posibilidad de no responder, sin necesidad de justificación.

La asignación de los participantes a cada grupo (GI o C) se realizó automáticamente en la página web en la que estaba incorporado el cuestionario (Google Forms) independientemente del idioma seleccionado por el participante, y de forma enmascarada para el participante que no sabía en que grupo había sido asignado.

Para poder aceptar las respuestas se definieron como criterios de inclusión ser profesional de la visión o académico o también estudiante del área de la salud visual, excluyendo a aquellos estudiantes que indicaron que les faltaba más de un año para completar su formación.

Análisis de los datos

Se realizó un análisis estadístico comparativo entre los grupos de intervención y control con el fin de evaluar las diferencias en el desempeño de los participantes, así como en su percepción sobre el uso de la IA en la toma de decisiones. Para ello, se analizaron mediante tablas cruzadas las respuestas mediante un análisis de Chi-cuadrado (χ^2) y pruebas de comparación de medias entre los grupos y subgrupos definidos según la situación profesional, el tiempo de experiencia y la región de los participantes, utilizando Excel 365 y SPSS versión 29.

Para analizar el acuerdo de las respuestas con el AsV, se establecieron dos referencias. La primera, la concordancia con el AsV, determinada como el número de respuestas idénticas de los participantes a la recomendación del AsV. La segunda, la similitud con el AsV, que define el grado de alineación parcial con la recomendación del asistente puesto que los casos evaluaban triaje y derivación en un espectro amplio, sin un diagnóstico cerrado, algunas combinaciones de respuesta a pesar de no coincidir exactamente con el AsV, no pueden clasificarse como completamente discrepantes. Por ejemplo, si el asistente sugiere derivar a optometría y oftalmología, y el participante elige solo una de estas opciones, se asigna una similitud proporcional (ej., 50%). Esta métrica permite evaluar la correspondencia entre las decisiones clínicas humanas y las del AsV basado en IA sin reducir el análisis a una medida dicotómica de acierto/error.

Igualmente se definió el porcentaje de acierto en las respuestas válidas, es decir, sin incluir las omisiones ($t\%$) y en el total de respuestas, incluyendo todas las alternativas de respuesta ($\%T$) en los grupos de intervención y control.



8.3. Resultados

Se recogieron 321 respuestas que tras aplicar los criterios de inclusión se eliminaron 11 participantes de manera que la muestra final para el análisis fue de 310 participantes de los cuales se asignaron al GI 156 y al GC 154, La muestra estuvo conformada por 191 hombres (60%) y 128 mujeres (40%), con una edad media de $43,2 \pm 11,8$ años, procedentes de 12 países, sin diferencias significativas entre los grupos de estudio (Tabla 8.1).

En cuanto a las respuestas a los casos clínicos, detalladas en la Tabla 8.2 e ilustradas en la Figura 8.2, se observaron respuestas diferentes entre ambos grupos. En el caso A, la opción más frecuente fue '*Problema refractivo y, motor y patológico*', coincidiendo en ambos grupos, aunque en diferentes proporciones (23,5% en el GI y 30,2% en el GC). La opción propuesta por el AsV obtuvo un 15,0% en el GI y un 5,8% en el GC ($P=0,01$). De manera similar, en el caso B, la mayoría de los participantes identificaron '*Problemas de vergencia y acomodativo*', resultado alineado con la respuesta del AsV.

Tabla 8.1. Resumen descriptivo de los registros analizados

Perfil	Todos	Grupo I	Grupo C	P valor
n	310	156	154	-
Número de países	12	11	11	0,952
Edad	43,2 ± 11,8	42,4 ± 11,4	43,9 ± 12,2	0,266
Sexo (M/F)	184 / 124	91 / 64	93 / 60	0,710
Situación profesional				
Óptico-Optometrista	256	131	125	0,799
Profesor universitario	33	15	18	
Estudiante	21	10	11	
Experiencia				
Más de 15 años	172	83	89	0,132
De 5 a 15 años	86	41	45	
Menos de 5 años	40	27	13	
Estudiante último curso	12	5	7	
Región				
América	130	64	66	0,744
Argentina	9	4	5	
Bolivia	2	1	1	
Brasil	70	35	35	
Chile	1	0	1	
Colombia	23	11	12	
Ecuador	11	5	6	
Estados Unidos	3	2	1	
México	9	4	5	
Perú	2	2	0	
Europa	180	92	88	
España	134	71	63	
Portugal	31	14	17	
Reino Unido	15	7	8	

Por otro lado, en el caso C, las respuestas se concentraron en ‘*Problemas patológicos del polo anterior y posterior*’, con 39,6% en el GI y 46% en el GC. En esta ocasión, la coincidencia con la respuesta del AsV, con una ligera diferencia, ocupó la segunda posición, con 38,1% y 31,7%, respectivamente. En el caso D, predominó la categoría ‘*Problema refractivo y patológico*’, con 53,6% en el GI y 48% en el GC, manteniendo concordancia con el AsV. No obstante, el manejo real

estuvo vinculado a '*Problema refractivo y motor*', lo que se distanció tanto de la recomendación del AsV como de las respuestas de los participantes, quienes seleccionaron esta opción en un 2,6% en el GI y un 4,1% en el GC.

En cuanto al caso E, las respuestas estuvieron divididas. En el GI, el 47,1% optó por 'problema de vergencia', en concordancia con el AsV, mientras que en el GC predominó la clasificación de '*Problemas acomodativos*' (44%). En este mismo grupo, solo el 32% coincidió con la respuesta del AsV. Finalmente, en el caso F, la mayor parte de los participantes de ambos grupos identificó el problema como '*Patológico en el polo anterior*', con 52% en el GI y 65,4% en el GC. En contraste, la opción '*Sin problemas de orden patológico*', que coincidió con el AsV, fue seleccionada por el 20,3% en el GI y apenas por el 7,4% en el GC.

Se observó una menor proporción de omisiones en el GI en comparación con el GC en la mayoría de los casos clínicos, con diferencias estadísticamente significativas en los casos A y F, así como en la media general ($P < 0,01$, Tabla 8.3-A). Además, el GI presentó una mayor concordancia con el AsV en todos los casos, siendo la diferencia más notable en los casos A, E y F ($P < 0,01$, Tabla 8.3-A), con un total de 4,2% de omisiones en el GI y 8,6% en el GC ($P = 0,011$). En cuanto a la similitud con el AsV, los valores fueron consistentemente más altos en el GI, con diferencias significativas en los casos E y F ($P < 0,01$). En la comparación de todos los casos, el GI obtuvo un mayor porcentaje de concordancia (40,5% frente a 31,8% en el GC, $P < 0,01$) y también fue ligeramente mayor en el porcentaje de similitud (67,2% en el GI frente a 57,1% en el GC, $P < 0,05$). Los detalles y la representación gráfica se muestran en la Tabla 8.3-A y en la Figura 8.3, respectivamente.

Tabla 8.2. Resumen del porcentaje de respuestas de los participantes para los casos clínicos presentados (en negrita se destaca la respuesta propuesta por el AsV). Los valores con fondo verde representan la respuesta más frecuente, en azul el porcentaje de coincidencia con la respuesta del asistente virtual y en amarillo cuando la respuesta más frecuente y la del asistente coinciden. Las respuestas en negrita representan la respuesta real del caso, mientras que las respuestas subrayadas corresponden a la sugerencia del asistente. t% = porcentaje considerando solo las respuestas clínicas válidas; %T = porcentaje considerando todas las alternativas, incluidas las omisiones.

Caso	Respuestas	Grupo I			Grupo C		
		n	t %	T %	n	t %	T %
A	Problema sólo refractivo	24	15,7	15,4	22	15,8	14,3
	Problema refractivo y motor	36	23,5	23,1	42	30,2	27,3
	Problema refractivo y patológico	29	19,0	18,6	26	18,7	16,9
	Problema refractivo, motor y patológico	23	15,0	14,7	8	5,8	5,2
	Problema solo motor	11	7,2	7,1	11	7,9	7,1
	Problema motor y patológico	10	6,5	6,4	9	6,5	5,8
	Problema sólo patológico	20	13,1	12,8	17	12,2	11,0
	Ninguno	0	0,0	0,0	4	2,9	2,6
	<i>No es mi área o sin suficiente información</i>	3		1,9	14		9,1
	<i>No quiero responder</i>	0		0,0	1		0,6
TOTAL		156	100	100	154	100	100
B	Problema de vergencia	27	17,8	17,3	38	25,0	24,7
	Problema acomodativo	15	9,9	9,6	17	11,2	11,0
	Problema de vergencia y acomodativo	104	68,4	66,7	94	61,8	61,0
	Sin problemas oculomotores	6	3,9	3,8	3	2,0	1,9
	<i>No es mi área o sin suficiente información</i>	4		2,6	2		1,3
	<i>No quiero responder</i>	0		0	0		0
	TOTAL	156	100	100	154	100	100
C	Problema patológico en el polo anterior	21	15,1	13,5	19	15,1	12,3
	Problema patológico en el polo posterior	53	38,1	34,0	40	31,7	26,0
	Problema patológico en polo anterior y posterior	55	39,6	35,3	58	46,0	37,7
	Sin problemas de orden patológico	10	7,2	6,4	9	7,1	5,8
	<i>No es mi área o sin suficiente información</i>	16		10,3	26		16,9
	<i>No quiero responder</i>	1		0,6	2		1,3
	TOTAL	156	100	100	154	100	100

Caso	Respuestas	Grupo I			Grupo C		
		n	t %	T %	n	t %	T %
D	Problema sólo refractivo	61	39,9	39,1	63	42,6	40,9
	Problema refractivo y motor	4	2,6	2,6	6	4,1	3,9
	<u>Problema refractivo y patológico</u>	82	53,6	52,6	71	48,0	46,1
	Problema refractivo, motor y patológico	4	2,6	2,6	2	1,4	1,3
	Problema solo motor	0	0,0	0,0	0	0,0	0,0
	Problema motor y patológico	1	0,7	0,6	0	0,0	0,0
	Problema sólo patológico	1	0,7	0,6	6	4,1	3,9
	Ninguno	0	0,0	0	0	0,0	0,0
	<i>No es mi área o sin suficiente información</i>	3		1,9	6		3,9
	<i>No quiero responder</i>	0		0	0		0,0
TOTAL		156	100	100	154	100	100
E	<u>Problema de vergencia</u>	72	47,1	46,2	48	32,0	31,2
	Problema acomodativo	12	7,8	7,7	28	18,7	18,2
	Problema de vergencia y acomodativo	66	43,1	42,3	66	44,0	42,9
	Sin problemas oculomotores	3	2,0	1,9	8	5,3	5,2
	<i>No es mi área o sin suficiente información</i>	3		1,9	3		1,9
	<i>No quiero responder</i>	0		0	1		0,6
TOTAL		156	100	100	154	100	100
F	Problema patológico en el polo anterior	77	52,0	49,4	89	65,4	57,8
	Problema patológico en el polo posterior	8	5,4	5,1	15	11,0	9,7
	Problema patológico en el polo anterior y posterior	33	22,3	21,2	22	16,2	14,3
	<u>Sin problemas de orden patológico</u>	30	20,3	19,2	10	7,4	6,5
	<i>No es mi área o sin suficiente información</i>	6		3,8	17		11,0
	<i>No quiero responder</i>	2		1,3	1		0,6
TOTAL		156	100	100	154	100	100




Figura 8.2. Representación gráfica de la distribución de respuestas para cada caso del cuestionario.

Tabla 8.3. Resumen del acuerdo entre los participantes con el AsV. **A:** Todos los participantes segmentados por caso. **B:** Segmentado por subgrupos según situación profesional, experiencia y región. GI = Grupo I ('intervención'); GC = Grupo C ('control'); AsV = Asistente virtual.

A	Omisiones (n respuestas)			Concordancia AsV [%]			Similitud AsV		
	GI	GC	P	GI	GC	P	GI	GC	P
CASO A	3 (153)	15 (139)	0,003	23 [15,0%]	8 [5,8%]	0,01	59,7 %	54,7%	0,054
CASO B	4 (152)	2 (152)	0,419	104 [68,4%]	94 [61,8%]	0,229	82,2%	79,9%	0,699
CASO C	17 (139)	28 (126)	0,069	53 [38,1%]	40 [31,7%]	0,277	57,9%	54,8%	0,494
CASO D	3 (153)	6 (148)	0,301	82 [53,6]	71 [48,0]	0,329	76,8%	74,0%	0,331
CASO E	3 (153)	4 (150)	0,689	72 [47,1%]	48 [32,0%]	0,007	68,6%	54,0%	< 0,001
CASO F	8 (148)	18 (136)	0,037	30 [20,3%]	10 [7,4%]	0,002	57,4 %	48,2%	< 0,001
TOTAL	38 (898)	73 (851)	0,011	364 [40,5%]	271 [31,8%]	< 0,001	67,2%	57,1%	0,026

B	Omisiones			Concordancia AsV			Similitud AsV		
	GI	GC	P	GI	GC	P	GI	GC	P
<i>Óptico-Optometrista</i>	4,7%	8,4%	0,023	40,2%	30,7%	< 0,001	63,9%	55,4%	< 0,001
<i>Profesor universitario</i>	1,1%	9,3%	0,181	55,1%	44,9%	0,235	70,6%	61,3%	0,163
<i>Estudiante</i>	0,0%	0,0%	-	45,0%	39,4%	0,593	64,4%	62,1%	0,736
<i>Más de 15 años</i>	3,8%	8,4%	0,031	42,2%	34,0%	< 0,001	65,5%	57,6%	< 0,001
<i>De 5 a 15 años</i>	4,1%	8,9%	0,076	42,0%	33,7%	< 0,001	64,9%	54,2%	< 0,001
<i>Menos de 5 años</i>	5,6%	5,1%	0,910	34,0%	31,1%	0,272	60,8%	58,6%	0,664
<i>Europa</i>	5,6%	11,7%	0,01	39,9%	33,9%	0,003	62,7%	55,6%	0,002
<i>América</i>	1,8%	2,5%	0,446	41,4%	29,4%	0,001	67,3%	57,8%	< 0,001




Figura 8.3. Número de respuestas obtenidas en los casos presentados en el cuestionario. Los círculos rojos representan diferencias estadísticamente significativas ($P < 0,05$) entre los grupos. **A:** Porcentaje de concordancia con el asistente virtual. Las líneas discontinuas representan la similitud total con el asistente. **B:** Número de participantes que no respondieron al caso.

En el análisis por subgrupos (Tabla 8.3-B), se verificó que los ópticos-optometristas y los participantes con más de 5 años de experiencia presentaron una menor proporción de omisiones y mayores niveles de concordancia y similitud con el AsV en comparación con el GC ($P < 0,01$). Regionalmente, los participantes de América y Europa mostraron porcentajes similares de concordancia y similitud, siendo ligeramente mayores en el GI ($P = 0,003$). Finalmente, los participantes de Europa presentaron un mayor número de omisiones ($P = 0,01$).

En cuanto a las preguntas 11 y 13, que evalúan la confianza en las decisiones, los resultados presentados en la Tabla 8.4 y la Figura 8.4 indican que el nivel de confianza en la respuesta a los casos E y F varió entre el GI y el GC, con una diferencia significativa en el caso F ($P = 0,044$), siendo la confianza media ligeramente mayor en el GC. En el análisis dentro del GI, se observó que, en ambos casos, aquellos que siguieron la recomendación del AsV mostraron un nivel de confianza ligeramente superior en comparación con quienes no la siguieron, con una diferencia significativa en el caso E ($P = 0,037$). Además, el número de omisiones fue marcadamente diferente, ya que quienes siguieron la recomendación del AsV registraron solo 1 y 2 omisiones en los casos E y F, respectivamente, mientras que aquellos que no siguieron la misma respuesta del AsV presentaron 6 y 11 omisiones en los mismos casos.

Tabla 8.4. Resumen estadístico de las respuestas 11 y 13, que informan, en una escala de Likert (1 - poco a 5 - mucho), el nivel de confianza en la respuesta al caso. **A:** Confianza relacionada con el caso E. **B:** Confianza relacionada con el caso F. A la derecha de cada tabla, se presenta un análisis comparativo dentro del grupo I ('intervención') entre aquellos que siguieron la orientación del asistente y los que no. DE=Desviación estándar.

A	Grupo I	Grupo C	(Grupo I) ¿Coincidió con el AsV en el caso E?	
	n (%)	n (%)	No	Sí
5	24 (16,1)	24 (16,3)	9	3
4	56 (37,6)	63 (42,9)	30	26
3	56 (37,6)	43 (29,3)	29	27
2	12 (8,0)	13 (8,8)	9	15
1	1 (0,7)	4 (2,7)	1	0
TOTAL	149	147	78	71
Media ± DE	3,6 ± 0,9	3,6 ± 1,0	3,5 ± 0,9	3,8 ± 0,8
<i>P valor</i>		0,939	0,037	
			0,265*	0,250*
			* Comparación con el grupo C	
<i>Omisiones</i>	7	7	6	1

B	Grupo I	Grupo C	(Grupo I) ¿Coincidió con el AsV en el caso F?	
	n (%)	n (%)	No	Si
5	21 (14,7)	28 (21,1)	14 (12,2)	2 (7,1)
4	56 (39,2)	57 (42,9)	33 (28,7)	11 (39,3)
3	44 (30,8)	34 (25,6)	48 (41,7)	8 (28,6)
2	16 (11,2)	12 (9,0)	14 (12,2)	7 (25)
1	6 (4,2)	2 (1,5)	6 (5,2)	0
TOTAL	143	133	115	28
Media /DE	3,5 ± 1,0	3,7 ± 0,9	3,4 ± 1,0	3,7 ± 0,9
<i>P valor</i>		0,044	0,191	
			0,020*	0,939*
			* Comparación con el grupo C	
<i>Omisiones</i>	13	21	11	2




Figura 8.4. Nivel de confianza en los casos E y F. Los círculos rojos representan las diferencias estadísticamente significativas ($<0,05$). **A:** Respuestas en escala Likert (1 - poco a 5 - mucho). **B:** Representación de la media entre los grupos y la diferencia entre aquellos que siguieron la orientación del asistente en el grupo I.

En cuanto a la sección de opinión y percepción la Tabla 8.5 presenta los hallazgos correspondientes a las preguntas 14 y 15, ilustrados en la Figura 8.5-A, en una escala de acuerdo con 5 niveles. En general, los participantes estuvieron de acuerdo en que un AsV basado en IA que genere respuestas probabilísticas a situaciones clínicas podría ser útil para apoyar la toma de decisiones en la actividad profesional, con una valoración media de $3,9 \pm 0,8$. En cuanto a la percepción de confiabilidad respecto a las respuestas de aplicaciones, equipos o herramientas que utilizan algoritmos y modelos desarrollados con apoyo de IA, la media general fue de $3,5 \pm 0,8$, es decir, entre 'confío' y 'ni confío ni desconfío'.

El grado de acuerdo fue estadísticamente mayor en el grupo GC ($P = 0,023$) que en el GI. Al comparar las respuestas individuales, se observó un mayor porcentaje en el grupo GC (30,5%) en la opción '*5 - Totalmente de acuerdo*' ($P = 0,004$), frente al 15,8% del GI, mientras que en la opción '*4 – De acuerdo*' ocurrió lo contrario, con 58,8% en el grupo GI y 48,2% en el GC ($P > 0,05$). En la pregunta 15, la opción '*4 – Confío*' tuvo una mayor tasa de respuesta en el GC (53,8%) en comparación con el GI (42,5%), con un porcentaje inverso en la opción siguiente '*3 - No confío, no desconfío*', en la que el GC obtuvo menor porcentaje (31,1%) de respuestas que el GI (41,2%). Al analizar únicamente las respuestas dentro del GI, en relación con la medida de concordancia con las respuestas del AsV (Figura 8.5-B), se encontró que, a mayor concordancia, menor fue la ausencia de opinión en las preguntas 14 y 15, así como una mayor selección de la mejor alternativa, es decir, la opción 5 ($P < 0,05$) en comparación con las demás opciones.

Tabla 8.5. Resumen estadístico de la opinión de los participantes, en una escala de Likert descriptiva, sobre el uso de la tecnología digital en la atención visual primaria. A: Referente a la pregunta 14 sobre la utilidad de un asistente virtual en la vida profesional. B: Referente a la pregunta 15 sobre la percepción de confiabilidad de la inteligencia artificial

A	Grupo I	Grupo C	P valor	Todos
	n (%)	n (%)		n (%)
5 - Totalmente de acuerdo	21 (15,8)	43 (30,5)	0,004	64 (23,4)
4 - De acuerdo	78 (58,7)	68 (48,2)	0,084	146 (53,3)
3 - Ni de acuerdo ni en desacuerdo	25 (18,8)	24 (17,0)	0,703	49 (17,9)
2 - En desacuerdo	6 (4,5)	5 (3,6)	0,686	11 (4,0)
1 - Totalmente en desacuerdo	3 (2,3)	1 (0,7)	0,295	4 (1,5)
Total	133	141	0,023	274
Media	3,8 ± 0,8	4,0 ± 0,8		3,9 ± 0,8
Sin opinión (% sobre todos)	23 (14,7)	13 (8,4)	0,083	36 (11,6)

B	Grupo I	Grupo C	P valor	Todos
	n (%)	n (%)		n (%)
5 - Confío totalmente	5 (3,7)	7 (5,3)	0,522	12 (4,5)
4 - Confío	58 (42,7)	71 (53,8)	0,068	129 (48,1)
3 - No confío, no desconfío	56 (41,2)	41 (31,1)	0,085	97 (36,2)
2 - Desconfío	14 (10,3)	13 (9,8)	0,904	27 (10,1)
1 - Desconfío totalmente	3 (2,2)	0 (0)	0,087	3 (1,1)
Total	136	132	0,043	268
Media	3,4 ± 0,8	3,6 ± 0,8		3,5 ± 0,8
Sin opinión (% sobre todos)	20 (12,8)	22 (14,3)	0,707	42 (13,6)




Figura 8.5. Opinión sobre el uso de Asistentes Virtuales (14) y confianza en la inteligencia artificial (15). Los círculos rojos representan las diferencias estadísticamente significativas ($P < 0,05$). **A:** Respuestas de los participantes en escala Likert. El cuadro a la derecha, con fondo gris, resume la media de cada pregunta. **B:** Comparación de las medias en subgrupos del grupo I. AsV = Asistente virtual.

La Tabla 8.6 presenta los resultados correspondientes a la última pregunta del cuestionario (16), que hacía referencia a los sentimientos al pensar en el futuro rol profesional en relación con las tecnologías de salud digital, especialmente el uso de la IA aplicada a la salud visual. En términos de distribución específica, los sentimientos más reportados fueron ‘Tranquilo’ (25,9%), ‘Motivado’ (20,4%) y ‘Optimista’ (17,1%). El sentimiento negativo más frecuente fue ‘Preocupado’, con un 12,7%, ubicándose en la cuarta posición, mientras que las demás opciones negativas ocuparon los últimos lugares (Figura 8.6-A). En general, se observa un claro predominio de sentimientos positivos, con un 74,3% de participación, frente a solo un 17,2% de respuestas negativas (Figura 8.6-B).

Tabla 8.6. Resumen estadístico del sentimiento de los participantes sobre el futuro profesional en relación con las tecnologías de salud digital, especialmente el uso de la inteligencia artificial. En fondo azul, los sentimientos positivos; en rosa, los negativos; y en amarillo, los neutros.

Sentimiento	Grupo I	Grupo C	P valor	Todos
	n (%)	n (%)		n (%)
Tranquilo	75 (27,6)	70 (24,3)	0,645	145 (25,9)
Preocupado	39 (14,3)	32 (11,1)	0,378	71 (12,7)
Motivado	47 (17,3)	67 (23,3)	0,015	114 (20,4)
Desmotivado	2 (0,7)	6 (2,1)	0,149	8 (1,4)
Neutral/Indiferente	24 (8,8)	24 (8,3)	0,961	48 (8,6)
Desanimado	1 (0,4)	4 (1,4)	0,175	5 (0,9)
Animado	29 (10,7)	31 (10,8)	0,733	60 (10,7)
Pesimista	6 (2,2)	7 (2,4)	0,76	13 (2,3)
Optimista	49 (18)	47 (16,3)	0,866	96 (17,1)
Total	272	288	0,353	560
Positivos	202 (73,7)	218 (74,9)	0,189	420 (74,3)
Neutrales	24 (8,8)	24 (8,2)	0,961	48 (8,5)
Negativos	48 (17,5)	49 (16,8)	0,872	97 (17,2)

Además, solo una alternativa presentó diferencia significativa ($P = 0,015$) entre el GI y el GC: en la opción 'Motivado', obteniendo 17,3% y 23,3%, respectivamente. Por otro lado, en un análisis dentro del GI, se observó que aquellos que seleccionaron esta opción presentaron un mayor nivel de concordancia con las respuestas del AsV (Figura 8.6-C).




Figura 8.6. Resumen del sentimiento de los participantes sobre el futuro profesional en relación con las tecnologías de salud digital. Los círculos rojos representan las diferencias estadísticamente significativas ($P < 0,05$). **A:** Frecuencia de respuestas en orden descendente. **B:** Representación general de sentimientos positivos, negativos y neutros. **C:** Comparación de la selección de la opción 'Motivado' con la media de concordancia con el asistente. AsV = Asistente virtual.



8.4. Discusión

A pesar de los avances en la implementación de la IA en el ámbito de la salud, su uso en la toma de decisiones clínicas aún se enfrenta a desafíos relacionados con la confianza, fiabilidad y aceptación profesional además de la adaptación a contextos clínicos reales.^{288,291} Este trabajo ha evaluado el posible impacto del uso de un AsV basado en IA, analizando su influencia en las decisiones de los profesionales. Los resultados muestran que, si bien el AsV puede mejorar la precisión diagnóstica y reducir la indecisión, su aceptación está estrechamente vinculada a la transparencia en el proceso de toma de decisiones y a la familiaridad con el sistema²⁹⁰, de lo contrario, la IA puede generar dudas y afectar a la confianza en estas herramientas, tal y como han señalado en estudios previos sobre la integración de la IA en la atención de salud visual.²⁹²

Influencia en la toma de decisiones

Las respuestas a los casos evaluados muestran una gran variedad en las respuestas, sin que exista una opción de respuesta que sea claramente predominante, tal y como se ha reportado en un estudio con optometristas sobre la toma de decisiones relacionadas con el glaucoma.²⁹³ La Tabla 8.2 muestra que ninguno de los grupos la respuesta más prevalente supera el 70%, con una media del 48% para la respuesta más frecuente. Esto puede deberse a la naturaleza de los

casos, que pueden no requerir una sospecha diagnóstica concreta, sino predicciones generales relacionadas con el cribado del caso presentado. Además, la información clínica proporcionada a los participantes era limitada, incluyendo solo datos básicos (edad, sexo, agudeza visual) y pocos síntomas específicos, lo que puede favorecer la dispersión de respuestas en base de la diferente opinión de los profesionales que han respondido el cuestionario.

A pesar de la diferencia en los modelos de IA evaluados, donde la naturaleza de la predicción impide una evaluación dicotómica (correcto/incorrecto), los resultados encontrados son similares a los encontrados por estudios en los que se ha comparado la utilidad de la IA para el diagnóstico de la retinopatía diabética u otras patologías de retina, con tasas de concordancia entre los sistemas de IA y los especialistas cercanas al 60%.^{294,295} No obstante, el indicador de similitud promedio encontrado entre las respuestas de los participantes y las sugerencias del AsV fue del 67% en el GI y del 61% en el GC ($P < 0,001$), lo que indica que la concordancia con el asistente fue mayor que la coincidencia entre los propios participantes en torno a una respuesta mayoritaria.

Los resultados sugieren que conocer la respuesta proporcionada por un AsV puede ayudar a reducir la indecisión de los profesionales puesto que el porcentaje de profesionales que no responden (eligiendo las opciones de "*No es mi área*" o "*No tengo suficiente información*") en el GI (4,2%) fue estadísticamente menor que el encontrado en el GC (8,6%, $P = 0,011$) tal y como han señalado trabajo previo.²⁹⁶ Esto sugiere que la IA proporciona mayor seguridad y rapidez en la toma de decisiones reforzando la idea de que el uso de esta tecnología puede

favorecer el diagnóstico temprano y mejorar el pronóstico de diversas enfermedades.²⁹⁷

Asimismo, el AsV mostró un aumento general en la similitud con las respuestas del modelo de IA, con una diferencia de 7% entre el GI y el GC, lo que refuerza su influencia (Tabla 8.3-A). En términos de concordancia, el 40,5% de las respuestas del GI coincidieron con el AsV, frente al 31,8% en el GC ($P < 0,001$). Dado que en todos los casos analizados hubo un incremento en la selección de la alternativa sugerida por el asistente (Figura 8.3-A), parece que el conocer la opción propuesta por el AsV contribuyó a mejorar la precisión de los participantes, hallazgo alineado con los beneficios documentados sobre el uso de herramientas de apoyo basadas en IA en la salud.²⁹⁶ No obstante, estos resultados también sugieren que modelos con sesgos pueden influir en la toma de decisiones profesionales.²⁹⁸

En el caso D, donde la recomendación del AsV difería de la derivación real del paciente, no se observó una influencia negativa, ya que ambos grupos eligieron la misma opción mayoritaria. Este resultado favorece al modelo de IA, pues su error ocurrió en un contexto donde incluso los participantes del grupo control discreparon con el manejo final. Por otro lado, también resalta la capacidad de juicio profesional de los participantes con experiencia en el área de la salud ocular²⁹⁹, ya que la automatización de procesos puede ser un apoyo valioso, pero no sustituye el criterio del profesional.³⁰⁰

En contraste, los casos simulados E y F mostraron las mayores diferencias en la concordancia con el AsV, destacando su influencia en la toma de decisiones clínicas. Además, estos hallazgos reavivan el debate sobre el *overfitting* en modelos de IA, es decir, la adaptación

excesiva a los datos de entrenamiento, subrayando la importancia de la diversidad en los datos de entrenamiento para mejorar su capacidad de generalización en entornos clínicos reales.³⁰¹

Confianza en la toma de decisiones

Si bien el AsV facilitó la toma de decisiones, su impacto en la confianza de los participantes fue variable. En los casos E y F, analizados a través de las preguntas 11 y 13 (Tabla 8.4), la media de confianza en el caso E fue similar en ambos grupos (3,6 sobre 5), pero en el caso F, hubo una diferencia significativa ($P = 0,044$), con una media de 3,5 en el GI y de 3,7 en el GC. Aunque estos resultados confirman la influencia del AsV, sugieren que, en algunos casos, la IA puede haber generado dudas en la toma de decisiones.²⁹⁸

Para comprender este fenómeno, se analizó únicamente el GI, encontrando que los participantes que coincidieron con la opinión del AsV reportaron mayor confianza en su decisión, mientras que quienes discreparon mostraron una reducción en la autoconfianza (Figura 8.4-B). Esto sugiere que la discordancia con la IA, aunque mejore la precisión diagnóstica, puede generar incertidumbre en los profesionales, particularmente cuando no existe una relación de confianza con la herramienta.^{290,292}

Una posible explicación puede estar en la dificultad que pueden tener algunos profesionales para interpretar información probabilística, tal y como se presentó en el cuestionario.³⁰² En los casos E y F, se mostró la probabilidad de que la predicción del AsV fuera correcta (54% y 51%, respectivamente). Dado que estos valores no representan una certeza absoluta, es posible que los participantes dieran poco valor a

este valor, lo que pudo influir en la valoración de su confianza en su respuesta. Además, en el caso F, la opción del AsV fue "*Sin problemas de orden patológico*", una alternativa que, en los demás casos, fue la menos seleccionada. Esto sugiere un posible sesgo de acción, en el que los profesionales de la salud tienden a buscar activamente una solución o un diagnóstico en lugar de descartar la presencia de un problema.³⁰³

Otro factor relevante puede ser el desconocimiento del sistema, ya que los participantes no tuvieron acceso previo al AsV ni al nivel de precisión o acierto de sus modelos, lo que puede generar dudas sobre su fiabilidad, especialmente cuando la predicción difiere de su opinión. Esta falta de familiaridad podría haber afectado la confianza en sus recomendaciones, destacando la importancia de sistemas transparentes en la integración de la IA en salud.³⁰⁴

Opinión y percepción sobre el future

En relación con la percepción sobre la IA, los participantes reconocieron su potencial en la práctica clínica, aunque la confianza en estas herramientas sigue siendo moderada. En la pregunta 14 (utilidad del AsV), el GI obtuvo una media de 3,8, frente a 4,0 en el GC, mientras que en la pregunta 15 (confianza en la IA), el GI alcanzó 3,4 frente a 3,6 en el GC (Figura 8.5-A). Esto sugiere que la exposición a la respuesta del AsV puede influir en la percepción de los participantes, en línea con estudios previos que indican que la aceptación de la IA aumenta con el tiempo y con la familiarización con la tecnología.³⁰⁴ Además, este proceso también está condicionado por el dominio previo del usuario en el uso de herramientas similares.³⁰⁵

El análisis de la Tabla 8.5 revela un patrón de desplazamiento hacia niveles inferiores en la escala Likert, sugiriendo una redistribución de las respuestas hacia categorías de menor valoración. Por ejemplo, en el caso E, la puntuación máxima (5) fue seleccionada por 21 participantes en el GI y 43 en el GC ($P = 0,004$), mientras que en la categoría inmediatamente inferior (4), el GI obtuvo 78 respuestas frente a 68 en el GC. Un comportamiento similar se observó en el caso F, donde la opción 4 fue más seleccionada en el GC (71 respuestas) que en el GI (58), pero en la siguiente categoría (3) la tendencia se invirtió. Este desplazamiento sugiere que la asistencia del AsV puede haber influido en la confianza de los profesionales en la IA. Un análisis más detallado (Figura 8.5-B) dentro del GI refuerza esta hipótesis, mostrando que quienes otorgaron la máxima valoración (Likert 5) presentaban un mayor grado de concordancia con el AsV ($P < 0,05$). Además, aquellos que no dejaron su opinión tendieron a coincidir más con las predicciones del asistente, lo que indica que su influencia no solo afecta la toma de decisiones, sino que también puede estar relacionada por el grado de confianza y familiaridad con el sistema predictivo.

En cuanto al futuro de la profesión, la mayoría de los participantes expresó una visión positiva, con respuestas predominantes como "Tranquilo" y "Motivado". Sin embargo, el 12,7% manifestó preocupación, lo que puede reflejar la incertidumbre relacionada con la autonomía clínica, la sustitución profesional y la reducción de empleabilidad. Los resultados son coherentes con los hallazgos de otras investigaciones similares con profesionales en el ámbito de la salud visual.^{306–308}

El análisis presentó limitaciones, como por ejemplo en la segmentación, aunque mostraron diferencias significativas entre los grupos, especialmente en los subgrupos de ópticos-optometristas y profesionales con más de 15 años de experiencia, parecen seguir la tendencia general de los grupos. Sin embargo, su interpretación se ve limitada por el reducido tamaño muestral de algunos subgrupos. Otra limitación relevante es que los participantes no tuvieron contacto previo con el AsV ni acceso a datos sobre su desempeño, precisión y exactitud, lo que podría haber influido en los resultados. Aunque este estudio no tenía como objetivo evaluar la usabilidad del sistema, sino su influencia en la toma de decisiones, futuras investigaciones podrían explorar cómo la transparencia en la información del modelo y el uso del AsV, así como en otros perfiles de predicción, pueden impactar en las decisiones y en la confianza para su adopción en la práctica clínica.

8.5. Difusión

Resultados preliminares fueron presentados en 1er Seminario Nacional de Optometría, en Brasil (2025).

1er Seminario Nacional de Optometría de la Universidad del Contestado. Ponencia: **Apoyo a la toma de decisiones en atención visual primaria: asistente virtual basado en inteligencia artificial.** Stuermer L. al 30 de mayo de 2025. (Brasil).



Capítulo
Chapter

9

Desafíos y Líneas futuras

Challenges and Future lines



Aunque en cada capítulo se muestra una discusión específica de sus resultados que aborda las limitaciones metodológicas y las perspectivas de futuro asociadas a cada trabajo realizado, en este apartado se destacan algunos desafíos enfrentados durante el desarrollo de la Tesis Doctoral desde una perspectiva más amplia, así como las principales líneas futuras que se proponen a partir de los resultados encontrados.

Uno de los principales desafíos técnicos de este proyecto de investigación fue el acceso y la recolección de datos clínicos optométricos. Aunque estas cuestiones hayan sido discutidas en los capítulos correspondientes, su magnitud justifica un énfasis adicional. La dificultad para acceder a centros con alto volumen de datos clínicos, unida a la ausencia de sistemas digitalizados, obligó al uso de registros impresos que debieron ser manualmente catalogados, representando una barrera significativa a lo largo del desarrollo de la Tesis Doctoral. Esta situación demandó un esfuerzo considerable en términos de gestión personal y limitó tanto la estandarización como el volumen de información disponible para la construcción de modelos robustos.

A este panorama se suma la complejidad intrínseca del tema abordado, de naturaleza altamente novedosa y multidisciplinar, que integra saberes de la salud y la tecnología, y que demandó una construcción inicial amplia, progresiva y constante de marcos conceptuales, metodológicos y técnicos. Es decir, al mismo tiempo que

fue necesario comprender una línea de investigación aún incipiente dentro del grupo de estudio, también se requirió desarrollar conocimientos técnicos específicos para alcanzar los objetivos propuestos. En un campo en rápida evolución, este dinamismo representó simultáneamente una oportunidad y una fuente constante de adaptación en la investigación.

La falta de tradición investigadora en el área de la optometría en Brasil, contexto académico y profesional del doctorando, también representó una dificultad, ya que la inexistencia de grupos consolidados o redes científicas activas en el entorno próximo limita las oportunidades de intercambio metodológico orientado tanto a la comunicación como a la producción científica. A ello se sumó la distancia geográfica con el grupo de investigación de Optometría, que impuso al investigador un papel de autogestión intensiva a lo largo de todo el proceso, así como la necesidad de llevar adelante una experiencia investigadora más autónoma. No obstante, esta situación fue parcialmente mitigada gracias al acompañamiento del director de tesis, a la participación en eventos académicos internacionales, a los seminarios de investigación en línea organizados por el IOBA y a la estancia internacional realizada en el Reino Unido.

Finalmente, el contexto provocado por la pandemia global de la COVID-19 afectó significativamente la planificación y ejecución de varias etapas del proyecto, ya que las restricciones sanitarias y de movilidad impuestas repercutieron en los plazos y en la ejecución del trabajo, además de otras circunstancias de carácter más local que también tuvieron impacto en ese sentido.

Pese a estos desafíos, el trabajo logró alcanzar sus objetivos, y a partir de esta base pueden abrirse múltiples líneas futuras de investigación y desarrollo. Entre ellas, destaca la expansión de los modelos predictivos hacia otras condiciones visuales relevantes. En este sentido, la estancia de investigación realizada en Aston University permitió trabajar con datos orientados al manejo del ojo seco, lo que puede inspirar una nueva línea de estudio con un enfoque complementario al desarrollado en esta Tesis Doctoral.

Cabe considerar que los algoritmos de inteligencia artificial (IA) continúan evolucionando y que el acceso a los datos clínicos tiende a digitalizarse progresivamente. Además, los equipos actuales orientados a la salud ocular, especialmente los dispositivos de imagen permiten intercambios más ágiles para el análisis de datos, de manera que la integración futura de estos recursos de imagen con registros tabulares supone una oportunidad para mejorar la precisión diagnóstica y la aplicabilidad clínica del asistente virtual desarrollado. La combinación de estos factores favorece tanto la exploración de nuevas aplicaciones de la IA en el ámbito de la salud visual como la integración de elementos tecnológicos adicionales a la versión inicial del asistente, de modo que pueda consolidarse como una herramienta activa en el entorno clínico de los profesionales del área.

En esta misma línea, la implementación y evaluación de la plataforma propuesta para el almacenamiento de datos también constituye una vía concreta de mejora y profundización en investigaciones futuras. Dada la naturaleza sensible de la información y la amplitud de sus posibles usos, resulta imprescindible reforzar los protocolos de privacidad y consentimiento explícito, conforme a las

diferentes regulaciones nacionales o supranacionales. Del mismo modo, la consolidación de tecnologías de asistencia diagnóstica deberá contemplar las condiciones que aseguren la intervención oportuna y prioritaria del profesional humano, garantizando así la seguridad del paciente y una práctica clínico-asistencial responsable.


El conjunto de resultados contruidos en esta Tesis Doctoral representa un punto de partida para nuevas soluciones en salud visual apoyadas por tecnologías inteligentes, contribuyendo a posicionar a las ciencias de la visión en la vanguardia de la transformación digital.

Capítulo
Chapter

10

Conclusiones

Conclusions



General.

An artificial intelligence (AI)–based virtual assistant (VA) was developed through the integration of predictive models trained with optometric clinical data and oriented toward screening. Its implementation in an accessible and functional application enabled the generation of recommendations capable of supporting clinical decision-making in primary visual care (PVC) by professionals in the field.

1.

Digital technologies applied to vision sciences over the past decade are concentrated in AI, particularly in deep learning techniques, with a predominance of studies focused on posterior segment diseases. Scientific production is largely oriented toward specialized clinical support, with limited representation of topics related to PVC, revealing a gap and relatively unexplored potential for the development of digital solutions aimed at this level of care.

2.

Publicly available datasets in vision sciences exhibit a thematic concentration in specialized clinical areas, particularly the retina and surgery, with poorly standardized formats and scarce representation of data related to PVC. This situation highlights a heterogeneous and limited availability relative to current needs for access, diversity, and applicability in research projects targeting visual healthcare.

3.

A global platform for the storage of clinical data in visual health has been proposed, integrating established electronic health record (EHR) standards and features of existing repositories. This conceptual model is oriented towards optometry and PVC and aims to structure, protect, and share clinical data ethically and efficiently for both scientific and healthcare purposes.

4.

Three AI models have been generated, trained with structured optometric clinical data, enabling high-accuracy predictions for case classification, localization of ocular problems, and detection of binocular vision dysfunctions based on signs and symptoms, thus offering support for decision-making in PVC.

5.

A web application in the form of a VA has been developed, integrating AI models trained with optometric clinical data. It is structured into functional modules connected to the cloud, allowing predictions to be executed in an accessible, secure, and understandable way, facilitating its application both in PVC clinical practice and educational settings

6.

The influence of the VA on decision-making was evaluated, showing that its recommendations have a positive impact by increasing concordance and reducing omissions in professionals' responses. The general perception of professionals is favourable regarding its utility, although moderate levels of confidence were observed, reflecting the need to strengthen familiarization and transparency in the use of AI-based tools in visual health.



REFERENCIAS

REFERENCES

- 
1. World Health Organization. *World Report on Vision*. World Health Organization; 2019. Accessed July 17, 2025. <https://www.who.int/es/publications/i/item/9789241516570>
 2. Burton MJ, Ramke J, Marques AP, et al. The Lancet Global Health Commission on Global Eye Health: vision beyond 2020. *Lancet Glob Health*. 2021;9(4):e489-e551. doi:10.1016/S2214-109X(20)30488-5
 3. Yasmin S, Schmidt E. Primary eye care: opportunities for health system strengthening and improved access to services. *Int Health*. 2022;14(Supplement_1):i37-i40. doi:10.1093/inthealth/ihab062
 4. Ho S, Kalloniatis M, Ly A. Clinical decision support in primary care for better diagnosis and management of retinal disease. *Clin Exp Optom*. 2022;105(6):562-572. doi:10.1080/08164622.2021.2008791
 5. Keel S, Müller A, Block S, et al. Keeping an eye on eye care: monitoring progress towards effective coverage. *Lancet Glob Health*. 2021;9(10):e1460-e1464. doi:10.1016/S2214-109X(21)00212-6
 6. Cicinelli M, Marmamula S, Khanna R. Comprehensive eye care - Issues, challenges, and way forward. *Indian J Ophthalmol*. 2020;68(2):316. doi:10.4103/ijo.IJO_17_19
 7. Gogate PM, Phadke SP, Das T, et al. Vision centre helps reduce blindness and vision impairment. Proof of concept in a four-year longitudinal study in an urban area in India. *Indian J Ophthalmol*. 2022;70(5):1742-1748. doi:10.4103/ijo.IJO_2314_21
 8. Zhu Z, Wang Y, Qi Z, et al. Oculomics: Current concepts and evidence. *Prog Retin Eye Res*. 2025;106:101350. doi:10.1016/j.preteyeres.2025.101350
 9. Martin E, Cook AG, Frost SM, et al. Ocular biomarkers: useful incidental findings by deep learning algorithms in fundus photographs. *Eye*. 2024;38(13):2581-2588. doi:10.1038/s41433-024-03085-2
 10. Li H, Cao J, Grzybowski A, Jin K, Lou L, Ye J. Diagnosing Systemic Disorders with AI Algorithms Based on Ocular Images. *Healthcare*. 2023;11(12):1739. doi:10.3390/healthcare11121739
 11. Fatehi F, Samadbeik M, Kazemi A. What is Digital Health? Review of Definitions. Published online 2020. doi:10.3233/SHTI200696
 12. Lawrence K. Digital Health Equity. In: *Digital Health*. Exon Publications; 2022:121-130. doi:10.36255/exon-publications-digital-health-health-equity

13. Timmermans S, Kaufman R. Annual Review of Sociology Technologies and Health Inequities. Published online 2020. doi:10.1146/annurev-soc-121919
14. Pereira CS, Magalhães BCC, Machado FC, Novais VR, Carvalho T de A. COVID-19 e a ascensão das healthtechs como ferramentas de continuidade dos cuidados e educação em saúde: uma revisão narrativa digital. *Research, Society and Development*. 2021;10(15):e253101522709. doi:10.33448/rsd-v10i15.22709
15. HealthDataForum. Big Data: A New Era for Healthcare. 2023. <https://healthdataforum.eu/2023/03/01/big-data-a-new-era-for-healthcare/>
16. Negro-Calduch E, Azzopardi-Muscat N, Krishnamurthy RS, Novillo-Ortiz D. Technological progress in electronic health record system optimization: Systematic review of systematic literature reviews. *Int J Med Inform*. 2021;152:104507. doi:10.1016/j.ijmedinf.2021.104507
17. Li JPO, Liu H, Ting DSJ, et al. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Prog Retin Eye Res*. 2021;82:100900. doi:10.1016/j.preteyeres.2020.100900
18. Ryu S. Book Review: mHealth: New Horizons for Health through Mobile Technologies: Based on the Findings of the Second Global Survey on eHealth (Global Observatory for eHealth Series, Volume 3). *Healthc Inform Res*. 2012;18(3):231. doi:10.4258/hir.2012.18.3.231
19. Shah N, Martin G, Archer S, Arora S, King D, Darzi A. Exploring mobile working in healthcare: Clinical perspectives on transitioning to a mobile first culture of work. *Int J Med Inform*. 2019;125:96-101. doi:10.1016/j.ijmedinf.2019.03.003
20. Morjaria P, Massie J. mHealth for eye care: what is possible? *Community Eye Health*. 2022;35(114):16-17.
21. Golinelli D, Boetto E, Carullo G, Nuzzolese AG, Landini MP, Fantini MP. Adoption of digital technologies in health care during the COVID-19 pandemic: Systematic review of early scientific literature. *J Med Internet Res. JMIR Publications Inc*. 2020;22(11). doi:10.2196/22280
22. Saleem SM, Pasquale LR, Sidoti PA, Tsai JC. Virtual Ophthalmology: Telemedicine in a COVID-19 Era. *Am J Ophthalmol*. 2020;216:237-242. doi:10.1016/j.ajo.2020.04.029
23. Nagra M, Vianya-Estopa M, Wolffsohn JS. Could telehealth help eye care practitioners adapt contact lens services during the COVID-19 pandemic? *Contact Lens and Anterior Eye*. 2020;43(3). doi:10.1016/j.clae.2020.04.002
24. Parikh D, Armstrong G, Liou V, Husain D. Advances in Telemedicine in Ophthalmology. *Semin Ophthalmol*. 2020;35(4):210-215. doi:10.1080/08820538.2020.1789675

25. Chan M, Estève D, Fourniols JY, Escriba C, Campo E. Smart wearable systems: Current status and future challenges. *Artif Intell Med*. 2012;56(3):137-156. doi:10.1016/j.artmed.2012.09.003
26. Wu KY, Dave A, Carbonneau M, Tran SD. Smart Contact Lenses in Ophthalmology: Innovations, Applications, and Future Prospects. *Micromachines (Basel)*. 2024;15(7):856. doi:10.3390/mi15070856
27. Wu KY, Mina M, Carbonneau M, Marchand M, Tran SD. Advancements in Wearable and Implantable Intraocular Pressure Biosensors for Ophthalmology: A Comprehensive Review. *Micromachines (Basel)*. 2023;14(10):1915. doi:10.3390/mi14101915
28. Wawer Matos PA, Reimer RP, Rokohl AC, Caldeira L, Heindl LM, Große Hokamp N. Artificial Intelligence in Ophthalmology – Status Quo and Future Perspectives. *Semin Ophthalmol*. 2023;38(3):226-237. doi:10.1080/08820538.2022.2139625
29. Ramamurthy D, Srinivasan S, Chamarty S, Velappan T, Verkicharla P, Samuel Paulraj AK. Smart Devices in Optometry: Current and Future Perspectives to Clinical Optometry. *Clin Optom (Auckl)*. 2024;Volume 16:169-190. doi:10.2147/OPTO.S447554
30. Hubbard DC, Cox P, Redd TK. Assistive applications of artificial intelligence in ophthalmology. *Curr Opin Ophthalmol*. 2023;34(3):261-266. doi:10.1097/ICU.0000000000000939
31. Vayena E, Blasimme A, Cohen IG. Machine learning in medicine: Addressing ethical challenges. *PLoS Med*. 2018;15(11):e1002689. doi:10.1371/journal.pmed.1002689
32. Char DS, Shah NH, Magnus D. Implementing Machine Learning in Health Care - Addressing Ethical Challenges. *N Engl J Med*. 2018;378(11):981-983. doi:10.1056/NEJMp1714229
33. de Mello BH, Rigo SJ, da Costa CA, et al. Semantic interoperability in health records standards: a systematic literature review. *Health Technol (Berl)*. 2022;12(2):255-272. doi:10.1007/s12553-022-00639-w
34. Hassen D Ben. Mobile-aided diagnosis systems are the future of health care. *Eastern Mediterranean Health Journal*. 2020;26(9):1135-1140. doi:10.26719/emhj.20.042
35. Peyroteo M, Ferreira IA, Elvas LB, Ferreira JC, Lapão LV. Remote Monitoring Systems for Patients With Chronic Diseases in Primary Health Care: Systematic Review. *JMIR Mhealth Uhealth*. 2021;9(12):e28285. doi:10.2196/28285
36. Maher C, Singh B, Wylde A, Chastin S. Virtual health assistants: a grand challenge in health communications and behavior change. *Front Digit Health*. 2024;6:1418695. doi:10.3389/fdgth.2024.1418695

37. Curtis RG, Bartel B, Ferguson T, et al. Improving User Experience of Virtual Health Assistants: Scoping Review. *J Med Internet Res*. 2021;23(12):e31737. doi:10.2196/31737
38. Magrabi F, Ammenwerth E, McNair JB, et al. Artificial Intelligence in Clinical Decision Support: Challenges for Evaluating AI and Practical Implications A Position Paper from the IMIA Technology Assessment & Quality Development in Health Informatics Working Group and the EFMI Working Group for Assessment of Health Information Systems. *Yearb Med Inform*. Published online 2019. doi:10.1055/s-0039-1677903
39. Strasberg HR, Rhodes B, Del Fiore G, Jenders RA, Haug PJ, Kawamoto K. Contemporary clinical decision support standards using Health Level Seven International Fast Healthcare Interoperability Resources. *Journal of the American Medical Informatics Association*. 2021;28(8):1796-1806. doi:10.1093/jamia/ocab070
40. Heydon P, Egan C, Bolter L, et al. Prospective evaluation of an artificial intelligence-enabled algorithm for automated diabetic retinopathy screening of 30 000 patients. *Br J Ophthalmol*. 2020;105(5):723. doi:10.1136/BJOPHTHALMOL-2020-316594
41. Wang X, Ji Z, Ma X, et al. Automated Grading of Diabetic Retinopathy with Ultra-Widefield Fluorescein Angiography and Deep Learning. *J Diabetes Res*. 2021;2021:2611250. doi:10.1155/2021/2611250
42. Dicuonzo G, Galeone G, Shini M, Massari A. Towards the Use of Big Data in Healthcare: A Literature Review. *Healthcare*. 2022;10(7):1232. doi:10.3390/healthcare10071232
43. Andreu-Perez J, Poon CCY, Merrifield RD, Wong STC, Yang GZ. Big Data for Health. *IEEE J Biomed Health Inform*. 2015;19(4):1193. doi:10.1109/JBHI.2015.2450362
44. Zhang C, Zhao J, Zhu Z, et al. Applications of Artificial Intelligence in Myopia: Current and Future Directions. *Front Med (Lausanne)*. 2022;9. doi:10.3389/fmed.2022.840498
45. Doutreligne M, Degremont A, Jachiet PA, Lamer A, Tannier X. Good practices for clinical data warehouse implementation: A case study in France. *PLOS Digital Health.Public Library of Science*. 2023;2(7). doi:10.1371/journal.pdig.0000298
46. Pavlenko E, Strech D, Langhof H. Implementation of data access and use procedures in clinical data warehouses. A systematic review of literature and publicly available policies. *BMC Med Inform Decis Mak.BioMed Central Ltd*. 2020;20(1). doi:10.1186/s12911-020-01177-z
47. Gagalova KK, Angelica Leon Elizalde M, Portales-Casamar E, Görges M. What you need to know before implementing a clinical research data warehouse: Comparative review of integrated data repositories in health care

- institutions. *JMIR Form Res.* JMIR Publications Inc. 2020;4(8). doi:10.2196/17687
48. Das AV, Prashanthi GS, Das T, Narayanan R, Rani PK. Clinical profile and magnitude of diabetic retinopathy: An electronic medical record–driven big data analytics from an eye care network in India. *Indian J Ophthalmol.* 2021;69(11):3110-3117. doi:10.4103/ijo.IJO_1490_21
 49. Agrawal R, Prabakaran S. Big data in digital healthcare: lessons learnt and recommendations for general practice. *Heredity (Edinb).* 2020;124(4):525-534. doi:10.1038/s41437-020-0303-2
 50. Abdullah YI, Schuman JS, Shabsigh R, Caplan A, Al-Aswad LA. Ethics of Artificial Intelligence in Medicine and Ophthalmology. *Asia-Pacific Journal of Ophthalmology.* 2021;10(3):289-298. doi:10.1097/APO.0000000000000397
 51. Evans NG, Wenner DM, Cohen IG, et al. Emerging Ethical Considerations for the Use of Artificial Intelligence in Ophthalmology. *Ophthalmology Science.* 2022;2(2):100141. doi:10.1016/j.xops.2022.100141
 52. Moore M, Loughman J, Butler JS, Ohlendorf A, Wahl S, Flitcroft DI. Application of big-data for epidemiological studies of refractive error. *PLoS One.* 2021;16(4):e0250468. doi:10.1371/journal.pone.0250468
 53. Longwill S, Moore M, Flitcroft DI, Loughman J. Using electronic medical record data to establish and monitor the distribution of refractive errors,. *J Optom.* 2022;15:S32-S42. doi:10.1016/j.optom.2022.09.001
 54. Bernstein IA, Fernandez KS, Stein JD, Pershing S, Wang SY. Big data and electronic health records for glaucoma research. *Taiwan J Ophthalmol. Wolters Kluwer Medknow Publications.* 2024;14(3):352-359. doi:10.4103/tjo.TJO-D-24-00055
 55. Pham AT, Pan AA, Yohannan J. Big data in visual field testing for glaucoma. *Taiwan J Ophthalmol.* 2024;14(3):289-298. doi:10.4103/tjo.TJO-D-24-00059
 56. Ferretti A, Ienca M, Velarde MR, Hurst S, Vayena E. The Challenges of Big Data for Research Ethics Committees: A Qualitative Swiss Study. *Journal of Empirical Research on Human Research Ethics.* 2022;17(1-2):129-143. doi:10.1177/15562646211053538
 57. Wang S, Dai Y, Shen J, Xuan J. Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Sci Rep.* 2021;11(1):24039. doi:10.1038/s41598-021-03430-5
 58. D'anza B, Pronovost PJ. Original Articles Digital Health: Unlocking Value in a Post-Pandemic World. doi:10.1089/pop.2021.0031
 59. Schwalbe N, Wahl B. Artificial intelligence and the future of global health. *Lancet.* 2020;395:1579-1586. doi:https://doi.org/10.1016/S0140-6736(20)30226-9

60. Assi L, Chamseddine F, Ibrahim P, et al. A global assessment of eye health and quality of life a systematic review of systematic reviews. *JAMA Ophthalmol*. 2021;139(5):526-541. doi:10.1001/jamaophthalmol.2021.0146
61. Wu G, Zhao W, Wong A, Lee DA. Patients with floaters: Answers from virtual assistants and large language models. *Digit Health*. 2024;10. doi:10.1177/20552076241229933
62. Biswas S, Davies LN, Sheppard AL, Logan NS, Wolffsohn JS. Utility of artificial intelligence-based large language models in ophthalmic care. *Ophthalmic and Physiological Optics*. 2024;44(3):641-671. doi:10.1111/opo.13284
63. Aftab M. Voice UI - Comprehensive Tech Review. 2020. <https://mahnoor-aftab.medium.com/voice-ui-comprehensive-tech-review-ae6d02c15d88>
64. KeyReply. Healthcare Virtual Assistants: Benefits, Use Cases & Examples. 2025. Accessed July 17, 2025. <https://www.keyreply.com/blog/healthcare-virtual-assistants>
65. Wang MTM, Muntz A, Lim J, et al. Ageing and the natural history of dry eye disease: A prospective registry-based cross-sectional study. *Ocul Surf*. 2020;18(4):736-741. doi:10.1016/j.jtos.2020.07.003
66. Mishra S, Chaudhury P, Tripathy HK, et al. Enhancing health care through medical cognitive virtual agents. *Digit Health*. 2024;10. doi:10.1177/20552076241256732
67. Ahmed A, Hassan A, Aziz S, et al. Chatbot features for anxiety and depression: A scoping review. *Health Informatics J*. 2023;29(1). doi:10.1177/14604582221146719
68. Pravettoni G, Triberti S. A “P5” Approach to Healthcare and Health Technology. In: Pravettoni G, Triberti S, eds. *P5 EHealth: An Agenda for the Health Technologies of the Future*. Springer; 2020. doi:10.1007/978-3-030-27994-3_1
69. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med. Nature Publishing Group*. 2019;25(1):24-29. doi:10.1038/s41591-018-0316-z
70. Mese I, Inan NG, Kocadagli O, Salmaslioglu A, Yildirim D. ChatGPT-assisted deep learning model for thyroid nodule analysis: beyond artificial intelligence. *Med Ultrason*. 2023;25(4):375. doi:10.11152/mu-4306
71. Zhang Y, Tay Y, Lin Z, et al. Beyond Fully Supervised Learning: A Survey of Semi-Supervised, Self-Supervised and Unsupervised Learning in Vision. *arXiv preprint arXiv:210807258*. Published online 2021. <https://doi.org/10.48550/arXiv.2108.07258>

72. Khoraminia F, Fuster S, Kanwal N, et al. Artificial Intelligence in Digital Pathology for Bladder Cancer: Hype or Hope? A Systematic Review. *Cancers (Basel)*. 2023;15(18):4518. doi:10.3390/cancers15184518
73. Miller DD, Brown EW. Artificial Intelligence in Medical Practice: The Question to the Answer? *American Journal of Medicine*. 2018;131(2):129-133. doi:10.1016/j.amjmed.2017.10.035
74. Lyall DM, Kormilitzin A, Lancaster C, et al. Artificial intelligence for dementia—Applied models and digital health. *Alzheimer's & Dementia*. 2023;19(12):5872-5884. doi:10.1002/alz.13391
75. Deepchecks. F1 Score, Accuracy, ROC-AUC and PR-AUC Metrics for Models. 2025. Accessed July 17, 2025. <https://www.deepchecks.com/f1-score-accuracy-roc-auc-and-pr-auc-metrics-for-models/>
76. DataCamp. What Is a Confusion Matrix in Machine Learning? 2025. Accessed July 17, 2025. <https://www.datacamp.com/tutorial/what-is-a-confusion-matrix-in-machine-learning>
77. Ienca M, Ferretti A, Hurst S, Puhan M, Lovis C, Vayenaid E. Considerations for ethics review of big data health research: A scoping review. Published online 2018. doi:10.1371/journal.pone.0204937
78. Chun J, Kim Y, Shin KY, et al. Deep Learning–Based Prediction of Refractive Error Using Photorefractive Images Captured by a Smartphone: Model Development and Validation Study. *JMIR Med Inform*. 2020;8(5):e16225. doi:10.2196/16225
79. Espinosa J, Pérez J, Villanueva A. Prediction of Subjective Refraction From Anterior Corneal Surface, Eye Lengths, and Age Using Machine Learning Algorithms. *Transl Vis Sci Technol*. 2022;11(4):8. doi:10.1167/tvst.11.4.8
80. Ran AR, Cheung CY, Wang X, et al. Detection of glaucomatous optic neuropathy with spectral-domain optical coherence tomography: a retrospective training and validation deep-learning analysis. *Lancet Digit Health*. 2019;1(4):e172-e182. doi:10.1016/S2589-7500(19)30085-8
81. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy and Allied Technologies*. 2019;28(2):73-81. doi:10.1080/13645706.2019.1575882
82. 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. doi:10.1001/jama.2016.17216
83. Hitek P. What is the difference between regression and classification in machine learning. 2025. <https://panamahitek.com/en/what-is-the-difference-between-regression-and-classification-in-machine-learning>
84. Nespolo RG, Yi D, Cole E, Wang D, Warren A, Leiderman YI. Feature Tracking and Segmentation in Real Time via Deep Learning in Vitreoretinal

- Surgery. *Ophthalmol Retina*. 2023;7(3):236-242. doi:10.1016/j.oret.2022.10.002
85. Khal Y EI. Confusion Matrix, AUC and ROC Curve, and Gini—Clearly Explained. 2025. <https://yassineelkhal.medium.com/confusion-matrix-auc-and-roc-curve-and-gini-clearly-explained-221788618eb2>
86. De Fauw J, Ledsam JR, Romera-Paredes B, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med*. 2018;24:1342-1350. doi:10.1038/s41591-018-0107-6
87. Li S, Deng YQ, Zhu ZL, Hua HL, Tao ZZ. A Comprehensive Review on Radiomics and Deep Learning for Nasopharyngeal Carcinoma Imaging. *Diagnostics*. 2021;11(9):1523. doi:10.3390/diagnostics11091523
88. Kung TH, Cheatham M, Medenilla A, et al. Performance of ChatGPT on USMLE: Potential for AI-assisted medical education using large language models. *PLOS Digital Health*. 2023;2(2):e0000198. doi:10.1371/journal.pdig.0000198
89. Cohen IG, Evgeniou T, Gerke S, Minssen T. The European artificial intelligence strategy: implications and challenges for digital health. *Lancet Digit Health*. 2020;2(7):e376-e379. doi:10.1016/S2589-7500(20)30112-6
90. Ebrahimi F, Ayatollahi H, Aghaei H. A clinical decision support system for diagnosing and determining severity of dry eye disease. *Eye (Basingstoke)*. 2023;37(8):1619-1624. doi:10.1038/s41433-022-02197-x
91. Capulli E, Druda Y, Palmese F, et al. Ethical and legal implications of health monitoring wearable devices: A scoping review. *Soc Sci Med*. 2025;370:117685. doi:10.1016/j.socscimed.2025.117685
92. Peiffer-Smadja N, Rawson TM, Ahmad R, et al. Machine learning for clinical decision support in infectious diseases: a narrative review of current applications. *Clinical Microbiology and Infection. Elsevier B.V.* 2020;26(5):584-595. doi:10.1016/j.cmi.2019.09.009
93. Yu KH, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat Biomed Eng*. 2018;2(10):719-731. doi:10.1038/s41551-018-0305-z
94. Shortliffe EH, Buchanan BG. A model of inexact reasoning in medicine. *Math Biosci*. 1975;23(3-4):351-379. doi:10.1016/0025-5564(75)90047-4
95. Manyazewal T, Woldeamanuel Y, Blumberg HM, Fekadu A, Marconi VC. The potential use of digital health technologies in the African context: a systematic review of evidence from Ethiopia. doi:10.1038/s41746-021-00487-4
96. Hirani R, Noruzi K, Khuram H, et al. Artificial Intelligence and Healthcare: A Journey through History, Present Innovations, and Future Possibilities. *Life*. 2024;14(5):557. doi:10.3390/life14050557

97. Yang Q, Bee YM, Lim CC, et al. Use of artificial intelligence with retinal imaging in screening for diabetes-associated complications: systematic review. *EClinicalMedicine*. 2025;81:103089. doi:10.1016/j.eclinm.2025.103089
98. U.S. Government Accountability Office (GAO). Artificial Intelligence in Health Care: Benefits and Challenges of Technologies to Augment Patient Care. 2020. Accessed July 17, 2025. <https://www.gao.gov/products/gao-21-7sp>
99. Ting DSW, Pasquale LR, Peng L, et al. Artificial intelligence and deep learning in ophthalmology. *British Journal of Ophthalmology*. 2019;103(2):167-175. doi:10.1136/bjophthalmol-2018-313173
100. Srivastava O, Tennant M, Grewal P, Rubin U, Seamone M. Artificial intelligence and machine learning in ophthalmology: A review. *Indian J Ophthalmol*. 2023;71(1):11-17. doi:10.4103/IJO.IJO_1569_22
101. 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*. 2017;135(11):1170. doi:10.1001/JAMAOPHTHALMOL.2017.3782
102. Sánchez CI, García M, Mayo A, López MI, Hornero R. Retinal image analysis based on mixture models to detect hard exudates. *Med Image Anal*. 2009;13(4):650-658. doi:10.1016/j.media.2009.05.005
103. Romero-Oraá R, Herrero-Tudela M, López MI, Hornero R, García M. Attention-based deep learning framework for automatic fundus image processing to aid in diabetic retinopathy grading. *Comput Methods Programs Biomed*. 2024;249:108160. doi:10.1016/j.cmpb.2024.108160
104. Li W, Bian L, Ma B, et al. Interpretable Detection of Diabetic Retinopathy, Retinal Vein Occlusion, Age-Related Macular Degeneration, and Other Fundus Conditions. *Diagnostics*. 2024;14(2):121. doi:10.3390/diagnostics14020121
105. García G, Colomer A, Naranjo V. Glaucoma Detection from Raw SD-OCT Volumes: A Novel Approach Focused on Spatial Dependencies. *Comput Methods Programs Biomed*. 2021;200. doi:10.1016/J.CMPB.2020.105855
106. Medeiros FA, Jammal AA, Mariottoni EB. Detection of Progressive Glaucomatous Optic Nerve Damage on Fundus Photographs with Deep Learning. *Ophthalmology*. 2020;128(3):383. doi:10.1016/J.OPHTHA.2020.07.045
107. Tham YC, Liu Y, Leung CKS, et al. Glaucoma Diagnosis with Machine Learning Based on Optical Coherence Tomography and Color Fundus Images. *J Healthc Eng*. 2019;2019:1-13. doi:10.1155/2019/4061313

108. Lavric A, Valentin P. KeratoDetect: Keratoconus Detection Algorithm Using Convolutional Neural Networks. *Comput Intell Neurosci*. 2019;2019:8162567. doi:10.1155/2019/8162567
109. Kamiya K, Ayatsuka Y, Kato Y, et al. Keratoconus detection using deep learning of colour-coded maps with anterior segment optical coherence tomography: a diagnostic accuracy study. *BMJ Open*. 2019;9(9):e031313. doi:10.1136/BMJOPEN-2019-031313
110. Ting DSJ, Foo VH, Yang LWY, et al. Artificial intelligence for anterior segment diseases: Emerging applications in ophthalmology. *British Journal of Ophthalmology*. 2021;105(2):158-168. doi:10.1136/bjophthalmol-2019-315651
111. Wang J, Yeh TN, Chakraborty R, Yu SX, Lin MC. A Deep Learning Approach for Meibomian Gland Atrophy Evaluation in Meibography Images. *Transl Vis Sci Technol*. 2019;8(6):37. doi:10.1167/TVST.8.6.37
112. Long E, Chen J, Wu X, et al. Artificial intelligence manages congenital cataract with individualized prediction and telehealth computing. *NPJ Digit Med*. 2020;3(1):112. doi:10.1038/S41746-020-00319-X
113. Yamauchi T, Tabuchi H, Takase K, Masumoto H. Use of a Machine Learning Method in Predicting Refraction after Cataract Surgery. *J Clin Med*. 2021;10(5):1103. doi:10.3390/jcm10051103
114. Yang H, He J, Jiang Z, et al. Automated cornea diagnosis using deep convolutional neural networks based on cornea topography maps. *Sci Rep*. 2023;13(1):6720. doi:10.1038/s41598-023-33793-w
115. Xu M, Chen Y, Sun H, et al. A deep learning system for myopia onset prediction and intervention effectiveness evaluation in children. *NPJ Digit Med*. 2024;7(1):36. doi:10.1038/s41746-024-01204-7
116. Wu D, Huang X, Chen L, Hou P, Liu L, Yang G. Integrating artificial intelligence in strabismus management: current research landscape and future directions. *Exp Biol Med.Frontiers Media SA*. 2024;249. doi:10.3389/ebm.2024.10320
117. Chen Z, Fu H, Lo WL, Chi Z. Strabismus Recognition Using Eye-Tracking Data and Convolutional Neural Networks. *J Healthc Eng*. 2018;2018:1-9. doi:10.1155/2018/7692198
118. G Y, Paul A, Akash, K. CD, P C. AI-Powered Medical Diagnosis: Amblyopia Diagnosis and Prediction. *International Research Journal of Modernization in Engineering Technology and Science*. 2025;7(1). doi:10.56726/IRJMETS66736
119. Sankarnarayanan T, Paciorkowski L, Parikh K, et al. Training AI to Recognize Objects of Interest to the Blind and Low Vision Community. In: *2023 45th Annual International Conference of the IEEE Engineering in*

-
- Medicine & Biology Society (EMBC)*. IEEE; 2023:1-4.
doi:10.1109/EMBC40787.2023.10340454
120. Ruiz-Lozano RE, Soifer M, Zemborain ZZ, et al. Deep-learning based analysis of in-vivo confocal microscopy images of the subbasal corneal nerve plexus' inferior whorl in patients with neuropathic corneal pain and dry eye disease. *Ocul Surf*. 2024;34:241-246. doi:10.1016/j.jtos.2024.08.002
 121. Stegmann H, Werkmeister RM, Pfister M, et al. Deep learning segmentation for optical coherence tomography measurements of the lower tear meniscus. *Biomed Opt Express*. 2020;11(3):1539. doi:10.1364/BOE.386228
 122. Baldi PF, Abdelkarim S, Liu J, To JK, Ibarra MD, Browne AW. Vitreoretinal Surgical Instrument Tracking in Three Dimensions Using Deep Learning. *Transl Vis Sci Technol*. 2023;12(1):20. doi:10.1167/tvst.12.1.20
 123. Yeh HH, Jain AM, Fox O, Wang SY. PhacoTrainer: A Multicenter Study of Deep Learning for Activity Recognition in Cataract Surgical Videos. *Transl Vis Sci Technol*. 2021;10(13):23. doi:10.1167/tvst.10.13.23
 124. Joshi RC, Yadav S, Dutta MK, Travieso-Gonzalez CM. Efficient Multi-Object Detection and Smart Navigation Using Artificial Intelligence for Visually Impaired People. *Entropy*. 2020;22(9):941. doi:10.3390/e22090941
 125. Dai B, Yu Y, Huang L, et al. Application of neural network model in assisting device fitting for low vision patients. *Ann Transl Med*. 2020;8(11):702-702. doi:10.21037/atm.2020.02.161
 126. Wang J, Yeh TL, Wei Y, et al. Artificial Intelligence for the Diagnosis of Dry Eye Disease and Meibomian Gland Dysfunction: A Review. *Ocul Surf*. 2022;24:64-76. doi:10.1016/j.jtos.2022.03.001
 127. Oke I, VanderVeen D. Machine Learning Applications in Pediatric Ophthalmology. *Semin Ophthalmol*. 2021;36(4):210-217. doi:10.1080/08820538.2021.1890151
 128. Mihalache A, Popovic MM, Muni RH. Performance of an Artificial Intelligence Chatbot in Ophthalmic Knowledge Assessment. *JAMA Ophthalmol*. 2023;141(6):589. doi:10.1001/jamaophthalmol.2023.1144
 129. Weinreb RN, Lee AY, Baxter SL, et al. Application of Artificial Intelligence to Deliver Healthcare From the Eye. *JAMA Ophthalmol*. Published online May 8, 2025. doi:10.1001/jamaophthalmol.2025.0881
 130. An S, Teo K, McConnell M V., Marshall J, Galloway C, Squirrell D. AI explainability in oculomics: How it works, its role in establishing trust, and what still needs to be addressed. *Prog Retin Eye Res*. 2025;106:101352. doi:10.1016/j.preteyeres.2025.101352
 131. Ting DSW, Peng L, Varadarajan A V, et al. Deep learning in ophthalmology: The technical and clinical considerations. *Prog Retin Eye Res*. 2019;72:100759. doi:10.1016/j.preteyeres.2019.04.003

132. Parikh D, Armstrong G, Liou V, Husain D. Advances in Telemedicine in Ophthalmology. *Semin Ophthalmol*. 2020;35(4):210-215. doi:10.1080/08820538.2020.1789675
133. Aziz HA. Virtual Reality Programs Applications in Healthcare. *J Health Med Inform*. 2018;09(01):305. doi:10.4172/2157-7420.1000305
134. Bui DT, Barnett T, Hoang H, Chinthammit W. Tele-mentoring using augmented reality technology in healthcare: A systematic review. *Australasian Journal of Educational Technology*. 2021;37(4):68-88. doi:10.14742/ajet.6243
135. Alonso SG, Arambarri J, López-Coronado M, de la Torre Díez I. Proposing New Blockchain Challenges in eHealth. *J Med Syst*. 2019;43(3):43-64. doi:10.1007/s10916-019-1195-7
136. Valverde C, Garcia M, Hornero R, Lopez-Galvez M. Automated detection of diabetic retinopathy in retinal images. *Indian J Ophthalmol*. 2016;64(1):26-32. doi:10.4103/0301-4738.178140
137. Rodríguez-Vallejo M, Remón L, Monsoriu JA, Furlan WD. Designing a new test for contrast sensitivity function measurement with iPad. *J Optom*. 2015;8(2):101-108. doi:10.1016/j.optom.2014.06.003
138. Moss HE, Joslin CE, Rubin DS, Roth S. Big data research in neuro-ophthalmology: Promises and pitfalls. *Journal of Neuro-Ophthalmology*. 2019;39(4):480-486. doi:10.1097/WNO.0000000000000751
139. Ting DSJ, Foo VH, Yang LWY, et al. Artificial intelligence for anterior segment diseases: Emerging applications in ophthalmology. *British Journal of Ophthalmology*. 2021;105(2):158-168. doi:10.1136/bjophthalmol-2019-315651
140. Stevenson CH, Hong SC, Ogbuehi KC. Development of an artificial intelligence system to classify pathology and clinical features on retinal fundus images. *Clin Exp Ophthalmol*. 2019;47(4):484-489. doi:10.1111/ceo.13433
141. López MM, López MM, de la Torre Díez I, Jimeno JCP, López-Coronado M. mHealth App for iOS to Help in Diagnostic Decision in Ophthalmology to Primary Care Physicians. *J Med Syst*. 2017;41(5). doi:10.1007/s10916-017-0731-6
142. Sorkin DH, Janio EA, Eikey E V., et al. Rise in use of digital mental health tools and technologies in the United States during the COVID-19 pandemic: Survey study. *J Med Internet Res*. 2021;23(4):e26994. doi:10.2196/26994
143. Ye J. The role of health technology and informatics in a global public health emergency: Practices and implications from the COVID-19 pandemic. *JMIR Med Inform. JMIR Publications Inc*. 2020;8(7):e19866. doi:10.2196/19866

144. Li T, Bo W, Hu C, et al. Applications of deep learning in fundus images: A review. *Med Image Anal.* 2021;69:101971. doi:10.1016/j.media.2021.101971
145. Machin-Mastromatteo JD, Tarango J, Refugio Romo-González J. Impact of the COVID-19 pandemic on scientific production. Published online 2021. doi:10.1016/B978-0-323-88493-8.00020-3
146. Ting DSW, Pasquale LR, Peng L, et al. Artificial intelligence and deep learning in ophthalmology. *British Journal of Ophthalmology.Br J Ophthalmol.* 2019;103(2):167-175. doi:10.1136/bjophthalmol-2018-313173
147. Aktürk C. Bibliometric Analysis of Clinical Decision Support Systems. *Acta Informatica Pragensia 2021.* 2021;10(1):61-74. doi:10.18267/j.aip.146
148. Schmidt-Erfurth U, Sadeghipour A, Gerendas BS, Waldstein SM, Bogunović H. Artificial intelligence in retina. *Prog Retin Eye Res.* 2018;67:1-29. doi:10.1016/j.preteyeres.2018.07.004
149. Trinh M, Ghassibi M, Lieberman R. Artificial Intelligence in Retina. *Adv Ophthalmol Optom.* 2021;6:175-185. doi:10.1016/j.yao.2021.04.012
150. Sommer AC, Blumenthal EZ. Telemedicine in ophthalmology in view of the emerging COVID-19 outbreak. *Graefe's Archive for Clinical and Experimental Ophthalmology.* 2020;258(11):2341-2352. doi:10.1007/s00417-020-04879-2
151. Galetsi P, Katsaliaki K. Big data analytics in health: an overview and bibliometric study of research activity. *Health Info Libr J.Blackwell Publishing Ltd.* 2020;37(1):5-25. doi:10.1111/hir.12286
152. Soh Z, Cheng CY. Application of big data in ophthalmology. *Taiwan J Ophthalmol.* 2023;13(2):123. doi:10.4103/tjo.TJO-D-23-00012
153. Cheng CY, Soh Z Da, Majithia S, et al. Big data in ophthalmology. *Asia-Pacific Journal of Ophthalmology.Lippincott Williams and Wilkins.* 2020;9(4):291-298. doi:10.1097/APO.0000000000000304
154. Pershing S, Lum F. The American Academy of Ophthalmology IRIS Registry (Intelligent Research In Sight): current and future state of big data analytics. *Curr Opin Ophthalmol.* 2022;33(5):394-398. doi:10.1097/ICU.0000000000000869
155. Wu JH, Lin S, Moghimi S. Big data to guide glaucoma treatment. *Taiwan J Ophthalmol.* 2024;14(3):333-339. doi:10.4103/tjo.TJO-D-23-00068
156. Koch T. Welcome to the revolution: COVID-19 and the democratization of spatial-temporal data. *Patterns.Cell Press.* 2021;2(7). doi:10.1016/j.patter.2021.100272
157. Bhattacharya S, Hu Z, Butte AJ. Opportunities and Challenges in Democratizing Immunology Datasets. *Front Immunol.Frontiers Media S.A.* 2021;12. doi:10.3389/fimmu.2021.647536

158. Almada M, Midão L, Portela D, et al. Um Novo Paradigma em Investigação em Saúde: Dados FAIR (Localizáveis, Acessíveis, Interoperáveis, Reutilizáveis). *Acta Med Port.* 2020;33(12):828-834. doi:10.20344/amp.12910
159. Inau ET, Sack J, Waltemath D, Zeleke AA. Initiatives, Concepts, and Implementation Practices of the Findable, Accessible, Interoperable, and Reusable Data Principles in Health Data Stewardship: Scoping Review. *J Med Internet Res.* 2023;25:e45013. doi:10.2196/45013
160. Halfpenny W, Baxter SL. Towards effective data sharing in ophthalmology: data standardization and data privacy. *Curr Opin Ophthalmol.* Published online July 12, 2022. doi:10.1097/ICU.0000000000000878
161. Arora A, Wagner SK, Carpenter R, Jena R, Keane PA. The urgent need to accelerate synthetic data privacy frameworks for medical research. *Lancet Digit Health.Elsevier Ltd.* Preprint posted online 2024. doi:10.1016/S2589-7500(24)00196-1
162. Stuermer L, Martin R. Characterization of technologies in digital health applied in vision care. *J Optom.* 2022;15:S70-S81. doi:10.1016/j.optom.2022.09.005
163. Hufstedler H, Roell Y, Peña A, et al. Navigating data standards in public health: A brief report from a data-standards meeting. *J Glob Health.* 2024;14. doi:10.7189/JOGH.14.03024
164. Feldman K, Johnson RA, Chawla N V. The State of Data in Healthcare: Path Towards Standardization. *J Healthc Inform Res.Springer.* 2018;2(3):248-271. doi:10.1007/s41666-018-0019-8
165. Tegbaru D, Braverman L, Zietman AL, et al. ASTRO Journals' Data Sharing Policy and Recommended Best Practices. *Adv Radiat Oncol.* 2019;4(4):551-558. doi:10.1016/j.adro.2019.08.002
166. World Health Organization. *Sharing and Reuse of Health-Related Data for Research Purposes: WHO Policy and Implementation Guidance.*; 2022. Accessed July 17, 2025. <https://www.who.int/publications/i/item/9789240044968>
167. Hueso M, de Haro L, Calabia J, et al. Leveraging Data Science for a Personalized Haemodialysis. *Kidney Diseases.* 2020;6(6):385-394. doi:10.1159/000507291
168. Vesoulis ZA, Husain AN, Cole FS. Improving child health through Big Data and data science. *Pediatr Res.* 2023;93(2):342-349. doi:10.1038/s41390-022-02264-9
169. Parimbelli E, Wilk S, Cornet R, et al. A review of AI and Data Science support for cancer management. *Artif Intell Med.* 2021;117:102111. doi:10.1016/j.artmed.2021.102111

-
170. Moir J, Aggarwal S, Skondra D. Repurposing medications for treatment of age-related macular degeneration: Insights from novel approaches to data mining. *Exp Biol Med*. SAGE Publications Inc. 2023;248(9):798-810. doi:10.1177/15353702231181188
171. Raab R, Küderle A, Zakreuskaya A, et al. Federated electronic health records for the European Health Data Space. *Lancet Digit Health*. 2023;5(11):e840-e847. doi:10.1016/S2589-7500(23)00156-5
172. Kondylakis H, Kalokyri V, Sfakianakis S, et al. Data infrastructures for AI in medical imaging: a report on the experiences of five EU projects. *Eur Radiol Exp*. 2023;7(1). doi:10.1186/s41747-023-00336-x
173. Baxter SL, Lee AY. Gaps in standards for integrating artificial intelligence technologies into ophthalmic practice. *Curr Opin Ophthalmol*. 2021;32(5):431-438. doi:10.1097/ICU.0000000000000781
174. Espinoza J, Xu NY, Nguyen KT, Klonoff DC. The Need for Data Standards and Implementation Policies to Integrate CGM Data into the Electronic Health Record. *J Diabetes Sci Technol*. 2023;17(2):495-502. doi:10.1177/19322968211058148
175. Huang SC, Pareek A, Seyyedi S, Banerjee I, Lungren MP. Fusion of medical imaging and electronic health records using deep learning: a systematic review and implementation guidelines. *NPJ Digit Med*. 2020;3(1):136. doi:10.1038/s41746-020-00341-z
176. Nelson BW, Low CA, Jacobson N, Areán P, Torous J, Allen NB. Guidelines for wrist-worn consumer wearable assessment of heart rate in biobehavioral research. *NPJ Digit Med*. 2020;3(1):90. doi:10.1038/s41746-020-0297-4
177. Richesson RL. Learning health systems, embedded research, and data standards—recommendations for healthcare system leaders. *JAMIA Open*. 2021;3(4):488-491. doi:10.1093/jamiaopen/ooaa046
178. Novak JD. *Learning, Creating, and Using Knowledge*. Routledge; 1998. doi:10.4324/9781410601629
179. Cooper Y, Zimmerman E. Concept Mapping: A Practical Process for Understanding and Conducting Art Education Research and Practice. *Art Education*. 2020;73(2):24-32. doi:10.1080/00043125.2019.1695478
180. Heavner SF, Kumar VK, Anderson W, et al. Critical Data for Critical Care: A Primer on Leveraging Electronic Health Record Data for Research From Society of Critical Care Medicine's Panel on Data Sharing and Harmonization. *Crit Care Explor*. Lippincott Williams and Wilkins. 2024;6(11):e1179. doi:10.1097/CCE.0000000000001179
181. Gariépy-Saper K, Decarie N. Privacy of electronic health records: A review of the literature. *Journal of the Canadian Health Libraries Association*. 2021;42(1):74-84. doi:10.29173/jchla29496

182. Gamal A, Barakat S, Rezk A. Standardized electronic health record data modeling and persistence: A comparative review. *J Biomed Inform.Academic Press Inc.* 2021;114. doi:10.1016/j.jbi.2020.103670
183. Australian Optometry. *Refreshing Optometry 2040.*; 2024. Accessed July 17, 2025. https://www.optometry.org.au/wp-content/uploads/Policy/Advocacy/Optometry-2040-Report-2024-v3-1_compressed.pdf
184. The College of Optometrists. UK Eye Care Data Hub: forecasting eye care workforce and disease prevalence. January 21, 2025. Accessed July 17, 2025. <https://www.college-optometrists.org/viewpoint/advancing-optometry/uk-eye-care-data-hub>
185. Knapp AN, Leng T, Rahimy E. *Ophthalmology at the Forefront of Big Data Integration in Medicine: Insights from the IRIS Registry Database INTRODUCTION-THE BEGINNINGS OF BIG DATA.* Vol 96.; 2023.
186. Save Sight Registries. Fight Retinal Blindness! 2025. Accessed July 16, 2025. <https://savesightregistries.org/fight-retinal-blindness/>
187. American Optometric Association. AOA MORE, optometry's data registry, takes yearlong pause. AOA News. February 25, 2021. Accessed July 17, 2025. <https://www.aoa.org/news/practice-management/perfect-your-practice/aoa-more-takes-yearlong-pause?sso=y>
188. Optometry Australia. Big Data:Creating a national optometry dataset. Optometry 2040. 2018. Accessed July 17, 2025. <https://www.optometry.org.au/practice-professional-support/patient-practice-management/big-data/>
189. Leviton A, Loddenkemper T. Design, implementation, and inferential issues associated with clinical trials that rely on data in electronic medical records: a narrative review. *BMC Med Res Methodol.BioMed Central Ltd.* 2023;23(1). doi:10.1186/s12874-023-02102-4
190. Ittarat M, Cheungpasitporn W, Chansangpetch S. Personalized Care in Eye Health: Exploring Opportunities, Challenges, and the Road Ahead for Chatbots. *J Pers Med.Multidisciplinary Digital Publishing Institute (MDPI).* 2023;13(12). doi:10.3390/jpm13121679
191. Harding S, Alshukri A, Appelbe D, et al. Individualised variable-interval risk-based screening in diabetic retinopathy: the ISDR research programme including RCT. *Programme Grants for Applied Research.* Published online October 2023:1-72. doi:10.3310/HRFA3155
192. Higgins BE, Leonard-Hawkhead B, Azuara-Blanco A. Quality of Reporting Electronic Health Record Data in Glaucoma. *Ophthalmol Glaucoma.* 2024;7(5):422-430. doi:10.1016/j.ogla.2024.04.002
193. Ayaz M, Pasha MF, Alzahrani MY, Budiarto R, Stiawan D. The Fast Health Interoperability Resources (FHIR) Standard: Systematic Literature Review of

-
- Implementations, Applications, Challenges and Opportunities. *JMIR Med Inform.* 2021;9(7):e21929. doi:10.2196/21929
194. Meredith J, Whitehead N, Dacey M. Aligning Semantic Interoperability Frameworks with the FOXS Stack for FAIR Health Data. *Methods Inf Med.* Published online April 4, 2022. doi:10.1055/a-1993-8036
 195. Mukhiya SK, Lamo Y. An HL7 FHIR and GraphQL approach for interoperability between heterogeneous Electronic Health Record systems. *Health Informatics J.* 2021;27(3). doi:10.1177/14604582211043920
 196. European parliament and of the council. General Data Protection Regulation. Intersoft consulting. 2016. Accessed July 17, 2025. <https://gdpr-info.eu/>
 197. Tsai CH, Eghdam A, Davoody N, Wright G, Flowerday S, Koch S. Effects of electronic health record implementation and barriers to adoption and use: A scoping review and qualitative analysis of the content. *Life.* 2020;10(12):1-27. doi:10.3390/life10120327
 198. Bocquet F, Raimbourg J, Bigot F, Simmet V, Campone M, Frenel JS. Opportunities and Obstacles to the Development of Health Data Warehouses in Hospitals in France: The Recent Experience of Comprehensive Cancer Centers. *Int J Environ Res Public Health.* 2023;20(2):1645. doi:10.3390/ijerph20021645
 199. Godinho TM, Lebre R, Almeida JR, Costa C. ETL Framework for Real-Time Business Intelligence over Medical Imaging Repositories. *J Digit Imaging.* 2019;32(5):870-879. doi:10.1007/s10278-019-00184-5
 200. Bragazzi NL, Dai H, Damiani G, Behzadifar M, Martini M, Wu J. How big data and artificial intelligence can help better manage the covid-19 pandemic. *Int J Environ Res Public Health.* 2020;17(9). doi:10.3390/ijerph17093176
 201. Gagalova KK, Angelica Leon Elizalde M, Portales-Casamar E, Görges M. What you need to know before implementing a clinical research data warehouse: Comparative review of integrated data repositories in health care institutions. *JMIR Form Res. JMIR Publications Inc.* 2020;4(8). doi:10.2196/17687
 202. Stuermer L, Martin R. Characterization of technologies in digital health applied in vision care. *J Optom.* 2022;15 Suppl 1(Suppl 1):S70-S81. doi:10.1016/j.optom.2022.09.005
 203. de la Torre-Díez I, Martínez-Pérez B, López-Coronado M, Díaz JR, López MM. Decision support systems and applications in ophthalmology: literature and commercial review focused on mobile apps. *J Med Syst.* 2015;39(1):174. doi:10.1007/s10916-014-0174-2
 204. Oke I, VanderVeen D. Machine Learning Applications in Pediatric Ophthalmology. *Semin Ophthalmol.* 2021;36(4):210-217. doi:10.1080/08820538.2021.1890151

205. Rizzo S, Savastano A, Lenkowicz J, et al. Artificial Intelligence and OCT Angiography in Full Thickness Macular Hole. New Developments for Personalized Medicine. *Diagnostics (Basel)*. 2021;11(12). doi:10.3390/diagnostics11122319
206. Mahesh Kumar S V., Gunasundari R. Computer-Aided Diagnosis of Anterior Segment Eye Abnormalities using Visible Wavelength Image Analysis Based Machine Learning. *J Med Syst*. 2018;42(7):128. doi:10.1007/s10916-018-0980-z
207. Ting DSJ, Foo VH, Yang LWY, et al. Artificial intelligence for anterior segment diseases: Emerging applications in ophthalmology. *Br J Ophthalmol*. 2021;105(2):158-168. doi:10.1136/bjophthalmol-2019-315651
208. Espinosa J, Pérez J, Villanueva A. Prediction of Subjective Refraction From Anterior Corneal Surface, Eye Lengths, and Age Using Machine Learning Algorithms. *Transl Vis Sci Technol*. 2022;11(4):8. doi:10.1167/tvst.11.4.8
209. Yamauchi T, Tabuchi H, Takase K, Masumoto H. Use of a Machine Learning Method in Predicting Refraction after Cataract Surgery. *J Clin Med*. 2021;10(5):1103. doi:10.3390/jcm10051103
210. Wawer Matos PA, Reimer RP, Rokohl AC, Caldeira L, Heindl LM, Große Hokamp N. Artificial Intelligence in Ophthalmology - Status Quo and Future Perspectives. *Semin Ophthalmol*. 2023;38(3):226-237. doi:10.1080/08820538.2022.2139625
211. Potdar K, S. T, D. C. A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers. *Int J Comput Appl*. 2017;175(4):7-9. doi:10.5120/ijca2017915495
212. Chawla N V., Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*. 2002;16:321-357. doi:10.1613/jair.953
213. Chahid I, Elmiad AK, Badaoui M. Data Preprocessing For Machine Learning Applications in Healthcare: A Review. In: *Proceedings - SITA 2023: 2023 14th International Conference on Intelligent Systems: Theories and Applications*. Institute of Electrical and Electronics Engineers Inc.; 2023. doi:10.1109/SITA60746.2023.10373591
214. Joseph VR. Optimal ratio for data splitting. *Stat Anal Data Min*. 2022;15(4):531-538. doi:10.1002/sam.11583
215. Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks. *Inf Process Manag*. 2009;45(4):427-437. doi:10.1016/j.ipm.2009.03.002
216. Géron A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media; 2019.

-
217. Srivastava O, Tennant M, Grewal P, Rubin U, Seamone M. Artificial intelligence and machine learning in ophthalmology: A review. *Indian J Ophthalmol*. 2023;71(1):11-17. doi:10.4103/IJO.IJO_1569_22
218. Heydon P, Egan C, Bolter L, et al. Prospective evaluation of an artificial intelligence-enabled algorithm for automated diabetic retinopathy screening of 30 000 patients. *Br J Ophthalmol*. 2020;105(5):723. doi:10.1136/BJOPHTHALMOL-2020-316594
219. Wang X, Ji Z, Ma X, et al. Automated Grading of Diabetic Retinopathy with Ultra-Widefield Fluorescein Angiography and Deep Learning. *J Diabetes Res*. 2021;2021:2611250. doi:10.1155/2021/2611250
220. 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*. 2017;135(11):1170. doi:10.1001/JAMAOPHTHALMOL.2017.3782
221. Vaghefi E, Hill S, Kersten HM, Squirrell D. Multimodal Retinal Image Analysis via Deep Learning for the Diagnosis of Intermediate Dry Age-Related Macular Degeneration: A Feasibility Study. *J Ophthalmol*. 2020;2020:7493419. doi:10.1155/2020/7493419
222. Lavric A, Valentin P. KeratoDetect: Keratoconus Detection Algorithm Using Convolutional Neural Networks. *Comput Intell Neurosci*. 2019;2019:8162567. doi:10.1155/2019/8162567
223. Kamiya K, Ayatsuka Y, Kato Y, et al. Keratoconus detection using deep learning of colour-coded maps with anterior segment optical coherence tomography: a diagnostic accuracy study. *BMJ Open*. 2019;9(9):e031313. doi:10.1136/BMJOPEN-2019-031313
224. Shi C, Wang M, Zhu T, et al. Machine learning helps improve diagnostic ability of subclinical keratoconus using Scheimpflug and OCT imaging modalities. *Eye and Vision*. 2020;7(1):48. doi:10.1186/S40662-020-00213-3
225. Wang J, Yeh TN, Chakraborty R, Yu SX, Lin MC. A Deep Learning Approach for Meibomian Gland Atrophy Evaluation in Meibography Images. *Transl Vis Sci Technol*. 2019;8(6):37. doi:10.1167/TVST.8.6.37
226. Stegmann H, Werkmeister RM, Pfister M, et al. Deep learning segmentation for optical coherence tomography measurements of the lower tear meniscus. *Biomed Opt Express*. 2020;11(3):1539. doi:10.1364/BOE.386228
227. Girard F, Hurtut T, Kavalec C, Cheriet F. Atlas-based score for automatic glaucoma risk stratification. *Comput Med Imaging Graph*. 2021;87. doi:10.1016/J.COMPMEDIMAG.2020.101797
228. Orlando JI, Fu H, Barbossa Breda J, et al. REFUGE Challenge: A unified framework for evaluating automated methods for glaucoma assessment from

- fundus photographs. *Med Image Anal.* 2020;59. doi:10.1016/J.MEDIA.2019.101570
229. Thompson AC, Jammal AA, Medeiros FA. A Deep Learning Algorithm to Quantify Neuroretinal Rim Loss from Optic Disc Photographs. *Am J Ophthalmol.* 2019;201:9. doi:10.1016/J.AJO.2019.01.011
230. Ran AR, Cheung CY, Wang X, et al. Detection of glaucomatous optic neuropathy with spectral-domain optical coherence tomography: a retrospective training and validation deep-learning analysis. *Lancet Digit Health.* 2019;1(4):e172-e182. doi:10.1016/S2589-7500(19)30085-8
231. García G, Colomer A, Naranjo V. Glaucoma Detection from Raw SD-OCT Volumes: A Novel Approach Focused on Spatial Dependencies. *Comput Methods Programs Biomed.* 2021;200. doi:10.1016/J.CMPB.2020.105855
232. Medeiros FA, Jammal AA, Mariottoni EB. Detection of Progressive Glaucomatous Optic Nerve Damage on Fundus Photographs with Deep Learning. *Ophthalmology.* 2020;128(3):383. doi:10.1016/J.OPHTHA.2020.07.045
233. Ajitha S, Akkara JD, Judy M V. Identification of glaucoma from fundus images using deep learning techniques. *Indian J Ophthalmol.* 2021;69(10):2702. doi:10.4103/IJO.IJO_92_21
234. 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(7):803. doi:10.1001/JAMAOPHTHALMOL.2018.1934
235. Tong Y, Lu W, Deng Q qin, Chen C, Shen Y. Automated identification of retinopathy of prematurity by image-based deep learning. *Eye and Vision.* 2020;7(1):40. doi:10.1186/S40662-020-00206-2
236. Long E, Chen J, Wu X, et al. Artificial intelligence manages congenital cataract with individualized prediction and telehealth computing. *NPJ Digit Med.* 2020;3(1):112. doi:10.1038/S41746-020-00319-X
237. Chun J, Kim Y, Shin KY, et al. Deep Learning–Based Prediction of Refractive Error Using Photorefractive Images Captured by a Smartphone: Model Development and Validation Study. *JMIR Med Inform.* 2020;8(5):e16225. doi:10.2196/16225
238. López MM, López MM, de la Torre Díez I, Jimeno JCP, López-Coronado M. mHealth App for iOS to Help in Diagnostic Decision in Ophthalmology to Primary Care Physicians. *J Med Syst.* 2017;41(5):81. doi:10.1007/s10916-017-0731-6
239. Guo X, Swenor BK, Smith K, Boland M V, Goldstein JE. Developing an Ophthalmology Clinical Decision Support System to Identify Patients for Low Vision Rehabilitation. *Transl Vis Sci Technol.* 2021;10(3):24. doi:10.1167/tvst.10.3.24

240. López MM, López MM, de la Torre Díez I, Jimeno JCP, López-Coronado M. A mobile decision support system for red eye diseases diagnosis: experience with medical students. *J Med Syst*. 2016;40(6). doi:10.1007/s10916-016-0508-3
241. Biswas S, Davies LN, Sheppard AL, Logan NS, Wolffsohn JS. Utility of artificial intelligence-based large language models in ophthalmic care. *Ophthalmic and Physiological Optics*. 2024;44(3):641-671. doi:10.1111/opo.13284
242. Assi L, Chamseddine F, Ibrahim P, et al. A global assessment of eye health and quality of life a systematic review of systematic reviews. *JAMA Ophthalmol.American Medical Association*. 2021;139(5):526-541. doi:10.1001/jamaophthalmol.2021.0146
243. Ting DSW, Pasquale LR, Peng L, et al. Artificial intelligence and deep learning in ophthalmology. *British Journal of Ophthalmology*. 2019;103(2):167-175. doi:10.1136/bjophthalmol-2018-313173
244. Burton MJ, Ramke J, Marques AP, et al. The Lancet Global Health Commission on Global Eye Health: vision beyond 2020. *Lancet Glob Health*. 2021;9(4):e489-e551. doi:10.1016/S2214-109X(20)30488-5
245. Li JPO, Liu H, Ting DSJ, et al. Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Prog Retin Eye Res*. 2021;82:100900. doi:10.1016/j.preteyeres.2020.100900
246. Petkovic D, Altman R, Wong M, Vigil A. Improving the explainability of Random Forest classifier - user centered approach. *Pac Symp Biocomput*. 2018;23:204-215.
247. Keskinbora K, Güven F. Artificial intelligence and ophthalmology. *Turk J Ophthalmol*. 2020;50(1):37-43. doi:10.4274/tjo.galenos.2020.78989
248. Stuermer L, Martin R. Characterization of technologies in digital health applied in vision care. *J Optom*. 2022;15:S70-S81. doi:10.1016/j.optom.2022.09.005
249. Roca S, Lozano ML, García J, Alesanco Á. Validation of a Virtual Assistant for Improving Medication Adherence in Patients with Comorbid Type 2 Diabetes Mellitus and Depressive Disorder. *Int J Environ Res Public Health*. 2021;18(22):12056. doi:10.3390/ijerph182212056
250. Gouda P, Ganni E, Chung P, et al. Feasibility of Incorporating Voice Technology and Virtual Assistants in Cardiovascular Care and Clinical Trials. *Curr Cardiovasc Risk Rep*. 2021;15(8):13. doi:10.1007/s12170-021-00673-9
251. Moret-Tatay C, Iborra-Marmolejo I, Jorques-Infante MJ, Esteve-Rodrigo JV, Schwanke CHA, Irigaray TQ. Can Virtual Assistants Perform Cognitive Assessment in Older Adults? A Review. *Medicina (B Aires)*. 2021;57(12):1310. doi:10.3390/medicina57121310


252. Vidler LR, Baumgartner MP. Creating a Virtual Assistant for Medicinal Chemistry. *ACS Med Chem Lett*. 2019;10(7):1051-1055. doi:10.1021/acsmchemlett.9b00151
253. Aggarwal A, Tam CC, Wu D, Li X, Qiao S. Artificial Intelligence-Based Chatbots for Promoting Health Behavioral Changes: Systematic Review. *J Med Internet Res*. 2023;25:e40789. doi:10.2196/40789
254. Hauschild AC, Martin R, Holst SC, Wienbeck J, Heider D. Guideline for software life cycle in health informatics. *iScience*. 2022;25(12):105534. doi:10.1016/j.isci.2022.105534
255. Hartson R, Pyla P. The Wheel: UX Processes, Lifecycles, Methods, and Techniques. In: *The UX Book*. Elsevier; 2019:27-48. doi:10.1016/B978-0-12-805342-3.00002-3
256. Mehta R, Nankivil D, Zielinski DJ, et al. Wireless, Web-Based Interactive Control of Optical Coherence Tomography with Mobile Devices. *Transl Vis Sci Technol*. 2017;6(1):5. doi:10.1167/tvst.6.1.5
257. Kern C, Fu DJ, Kortuem K, et al. Clinical science Implementation of a cloud-based referral platform in ophthalmology: making telemedicine services a reality in eye care. *Br J Ophthalmol*. 2020;104:312-317. doi:10.1136/bjophthalmol-2019-314161
258. Schweitzer M, Ostheimer P, Lins A, et al. Transforming Tele-Ophthalmology: Utilizing Cloud Computing for Remote Eye Care. In: 2024. doi:10.3233/SHTI240040
259. Sallam M. ChatGPT Utility in Healthcare Education, Research, and Practice: Systematic Review on the Promising Perspectives and Valid Concerns. *Healthcare*. 2023;11(6):887. doi:10.3390/healthcare11060887
260. Biswas S, Logan NS, Davies LN, Sheppard AL, Wolffsohn JS. Assessing the utility of ChatGPT as an artificial intelligence-based large language model for information to answer questions on myopia. *Ophthalmic and Physiological Optics*. Published online July 21, 2023. doi:10.1111/opo.13207
261. Vidal ME, Chudasama Y, Huang H, Purohit D, Torrente M. Integrating Knowledge Graphs with Symbolic AI: The Path to Interpretable Hybrid AI Systems in Medicine. *Journal of Web Semantics*. 2025;84:100856. doi:10.1016/j.websem.2024.100856
262. Amershi S, Weld D, Vorvoreanu M, et al. Guidelines for human-AI interaction. In: *Conference on Human Factors in Computing Systems - Proceedings*. Association for Computing Machinery; 2019. doi:10.1145/3290605.3300233
263. Turner-McGrievy GM, Hales SB, Schoffman DE, et al. Choosing between responsive-design websites versus mobile apps for your mobile behavioral intervention: presenting four case studies. *Transl Behav Med*. 2017;7(2):224-232. doi:10.1007/s13142-016-0448-y

264. Galavi Z, Montazeri M, Khajouei R. Which criteria are important in usability evaluation of mHealth applications: an umbrella review. *BMC Med Inform Decis Mak.* 2024;24(1). doi:10.1186/s12911-024-02738-2
265. Bellows L, Oke S, Johnson SL. Wireframe Testing to Inform an mHealth Intervention for Parents to Promote Healthy Eating and Activity in Preschoolers. *J Nutr Educ Behav.* 2024;56(8):S99-S100. doi:10.1016/j.jneb.2024.05.221
266. Mihalache A, Popovic MM, Muni RH. Performance of an Artificial Intelligence Chatbot in Ophthalmic Knowledge Assessment. *JAMA Ophthalmol.* 2023;141(6):589. doi:10.1001/jamaophthalmol.2023.1144
267. Bendotti H, Ireland D, Lawler S, BBIomedSc DO, Gartner C, Marshall HM. Introducing Quin: The Design and Development of a Prototype Chatbot to Support Smoking Cessation. *Nicotine and Tobacco Research.* 2024;26(5):612-620. doi:10.1093/ntr/ntad217
268. Rao Sangarsu R. Advancing Web Development with Single Page Applications (SPAs). *Journal of Scientific and Engineering Research* 284 *Journal of Scientific and Engineering Research.* 2019;6(3):284-288. www.jsaer.com
269. Lee M, Bin Mahmood ABS, Lee ES, Smith HE, Tudor Car L. Smartphone and Mobile App Use Among Physicians in Clinical Practice: Scoping Review. *JMIR Mhealth Uhealth.* 2023;11:e44765. doi:10.2196/44765
270. Rossi J. What rules the Internet? A study of the troubled relation between Web standards and legal instruments in the field of privacy. *Telecomm Policy.* 2021;45(6):102143. doi:10.1016/j.telpol.2021.102143
271. Arndt BG, Beasley JW, Watkinson MD, et al. Tethered to the EHR: Primary care physician workload assessment using EHR event log data and time-motion observations. *Ann Fam Med.* 2017;15(5):419-426. doi:10.1370/afm.2121
272. Puchades R, Ramos-Ruperto L. Artificial intelligence in clinical practice: Quality and evidence. *Revista Clínica Española (English Edition).* 2025;225(1):23-27. doi:10.1016/j.rceng.2024.11.001
273. Islam R, Patamsetti V, Gadhi A, et al. The Future of Cloud Computing: Benefits and Challenges. *International Journal of Communications, Network and System Sciences.* 2023;16(04):53-65. doi:10.4236/ijcns.2023.164004
274. Bernal J, Mazo C. Transparency of Artificial Intelligence in Healthcare: Insights from Professionals in Computing and Healthcare Worldwide. *Applied Sciences (Switzerland).* 2022;12(20). doi:10.3390/app122010228
275. Alves M, Seringa J, Silvestre T, Magalhães T. Use of Artificial Intelligence tools in supporting decision-making in hospital management. *BMC Health Serv Res.* 2024;24(1). doi:10.1186/s12913-024-11602-y

276. Guo Y, Huang C, Sheng Y, et al. Improve the efficiency and accuracy of ophthalmologists' clinical decision-making based on AI technology. *BMC Med Inform Decis Mak*. 2024;24(1). doi:10.1186/s12911-024-02587-z
277. Nagi F, Salih R, Alzubaidi M, et al. Applications of Artificial Intelligence (AI) in Medical Education: A Scoping Review. *Stud Health Technol Inform*. 2023;305:648-651. doi:10.3233/SHTI230581
278. Han ER, Yeo S, Kim MJ, Lee YH, Park KH, Roh H. Medical education trends for future physicians in the era of advanced technology and artificial intelligence: an integrative review. *BMC Med Educ*. 2019;19(1):460. doi:10.1186/s12909-019-1891-5
279. Butow P, Hoque E. Using artificial intelligence to analyse and teach communication in healthcare. *The Breast*. 2020;50:49-55. doi:10.1016/j.breast.2020.01.008
280. Li Z, Wang L, Wu X, et al. Artificial intelligence in ophthalmology: The path to the real-world clinic. *Cell Rep Med*. 2023;4(7):101095. doi:10.1016/j.xcrm.2023.101095
281. Tabuchi H. Understanding required to consider AI applications to the field of ophthalmology. *Taiwan J Ophthalmol*. 2022;12(2):123. doi:10.4103/tjo.tjo_8_22
282. Feng X, Xu K, Luo MJ, et al. Latest developments of generative artificial intelligence and applications in ophthalmology. *Asia-Pacific Journal of Ophthalmology*. 2024;13(4):100090. doi:10.1016/j.apjo.2024.100090
283. Artificial Intelligence Applications in Ophthalmology. *JMA J*. 2025;8(1):66-75. doi:10.31662/jmaj.2024-0139
284. Stuermer L, Braga S, Martin R, Wolffsohn JS. Artificial intelligence virtual assistants in primary eye care practice. *Ophthalmic and Physiological Optics*. 2025;45(2):437-449. doi:10.1111/opo.13435
285. Jin K, Li Y, Wu H, et al. Integration of smartphone technology and artificial intelligence for advanced ophthalmic care: A systematic review. *Advances in Ophthalmology Practice and Research.Elsevier Inc*. 2024;4(3):120-127. doi:10.1016/j.aopr.2024.03.003
286. Sun MT, Tran M, Singh K, Chang R, Wang H, Sun Y. Glaucoma and Myopia: Diagnostic Challenges. *Biomolecules*. 2023;13(3). doi:10.3390/biom13030562
287. Tan TF, Thirunavukarasu AJ, Jin L, et al. Artificial intelligence and digital health in global eye health: opportunities and challenges. *Lancet Glob Health.Elsevier Ltd*. 2023;11(9):e1432-e1443. doi:10.1016/S2214-109X(23)00323-6
288. Cao X, Yousefzadeh R. Extrapolation and AI transparency: Why machine learning models should reveal when they make decisions beyond their

- training. *Big Data Soc.* SAGE Publications Ltd. 2023;10(1). doi:10.1177/20539517231169731
289. Bajwa J, Munir U, Nori A, Williams B. Artificial intelligence in healthcare: transforming the practice of medicine. *Future Healthc J.* 2021;8(2):e188-e194. doi:10.7861/fhj.2021-0095
 290. Steerling E, Siira E, Nilsen P, Svedberg P, Nygren J. Implementing AI in healthcare—the relevance of trust: a scoping review. *Frontiers in Health Services.* Frontiers Media SA. 2023;3. doi:10.3389/frhs.2023.1211150
 291. Chustecki M. Benefits and Risks of AI in Health Care: Narrative Review. *Interact J Med Res.* 2024;13:e53616. doi:10.2196/53616
 292. González-Gonzalo C, Thee EF, Klaver CCW, et al. Trustworthy AI: Closing the gap between development and integration of AI systems in ophthalmic practice. *Prog Retin Eye Res.* Elsevier Ltd. 2022;90. doi:10.1016/j.preteyeres.2021.101034
 293. Ghaffar F, Furtado NM, Ali I, Burns C. Diagnostic Decision-Making Variability Between Novice and Expert Optometrists for Glaucoma: Comparative Analysis to Inform AI System Design. *JMIR Med Inform.* 2025;13:e63109. doi:10.2196/63109
 294. Lim JI, Regillo CD, Sadda SVR, et al. Artificial Intelligence Detection of Diabetic Retinopathy: Subgroup Comparison of the EyeArt System with Ophthalmologists' Dilated Examinations. *Ophthalmology Science.* 2023;3(1). doi:10.1016/j.xops.2022.100228
 295. Lim JI, Rachitskaya A V., Hallak JA, Gholami S, Alam MN. Artificial intelligence for retinal diseases. *Asia-Pacific Journal of Ophthalmology.* 2024;13(4):100096. doi:10.1016/j.apjo.2024.100096
 296. Chen M, Wang Y, Wang Q, et al. Impact of human and artificial intelligence collaboration on workload reduction in medical image interpretation. *NPJ Digit Med.* 2024;7(1). doi:10.1038/s41746-024-01328-w
 297. Parmar UPS, Surico PL, Singh RB, et al. Artificial Intelligence (AI) for Early Diagnosis of Retinal Diseases. *Medicina (Lithuania).* Multidisciplinary Digital Publishing Institute (MDPI). 2024;60(4). doi:10.3390/medicina60040527
 298. Jabbour S, Fouhey D, Shepard S, et al. Measuring the Impact of AI in the Diagnosis of Hospitalized Patients. *JAMA.* 2023;330(23):2275. doi:10.1001/jama.2023.22295
 299. Maehara H, Ueno Y, Yamaguchi T, et al. The importance of clinical experience in AI-assisted corneal diagnosis: verification using intentional AI misleading. *Sci Rep.* 2025;15(1):1462. doi:10.1038/s41598-025-85827-0
 300. Göndöcs D, Dörfler V. AI in medical diagnosis: AI prediction & human judgment. *Artif Intell Med.* 2024;149. doi:10.1016/j.artmed.2024.102769

301. Subramanian J, Simon R. Overfitting in prediction models – Is it a problem only in high dimensions? *Contemp Clin Trials*. 2013;36(2):636-641. doi:10.1016/j.cct.2013.06.011
302. Reyna VF, Nelson WL, Han PK, Dieckmann NF. How Numeracy Influences Risk Comprehension and Medical Decision Making. *Psychol Bull*. 2009;135(6):943-973. doi:10.1037/a0017327
303. Gopal DP, Chetty U, O'Donnell P, Gajria C, Blackadder-Weinstein J. Implicit bias in healthcare: clinical practice, research and decision making. *Future Healthc J*. 2021;8(1):40-48. doi:10.7861/fhj.2020-0233
304. Al-Roomi K, Alzayani S, Almarabheh A, et al. Familiarity and Applications of Artificial Intelligence in Health Professions Education: Perspectives of Students in a Community-Oriented Medical School. *Cureus*. Published online November 11, 2024. doi:10.7759/cureus.73425
305. Akinrinmade AO, Adebile TM, Ezuma-Ebong C, et al. Artificial Intelligence in Healthcare: Perception and Reality. *Cureus*. Published online September 20, 2023. doi:10.7759/cureus.45594
306. Gunasekeran D V., Zheng F, Lim GYS, et al. Acceptance and Perception of Artificial Intelligence Usability in Eye Care (APPRAISE) for Ophthalmologists: A Multinational Perspective. *Front Med (Lausanne)*. 2022;9. doi:10.3389/fmed.2022.875242
307. Ho S, Doig GS, Ly A. Attitudes of optometrists towards artificial intelligence for the diagnosis of retinal disease: A cross-sectional mail-out survey. *Ophthalmic and Physiological Optics*. 2022;42(6):1170-1179. doi:10.1111/opo.13034
308. Scanzera AC, Shorter E, Kinnaird C, et al. Optometrist's perspectives of Artificial Intelligence in eye care. *J Optom*. 2022;15:S91-S97. doi:10.1016/j.optom.2022.06.006



ANEXOS

ANNEXES

A**Aprovação ética para recopilación de datos (trámite colectivo)***[primera y última página]***PARECER CONSUBSTANCIADO DO CEP****DADOS DO PROJETO DE PESQUISA**

Título da Pesquisa: DESENVOLVIMENTO DE MODELOS DE MACHNE LEARNING PARA TOMADA DE DECISÕES CLÍNICAS E EDUCAÇÃO EM OPTOMETRIA

Pesquisador: Leandro Stuermer

Área Temática:

Versão: 2

CAAE: 60625322.3.0000.0117

Instituição Proponente: FUNDAÇÃO UNIVERSIDADE DO CONTESTADO - FUNC

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.646.656

Apresentação do Projeto:

As informações elencadas no campo Apresentação do Projeto foram retirados integralmente do arquivo informações básicas da Pesquisa (PB_Informações_Básicas do Projeto CAAE: 60625322.3.0000.0117)

O Data Science (ciência de dados) incluindo seus mais variados subcampos, com destaque para as análises estatísticas avançadas e aplicação em inteligência artificial, tem ganho muito destaque em seu uso na área da saúde. A Health Data Science (ciência de dados em saúde), se caracteriza pela análise profunda dos diferentes tipos de informações relacionadas a saúde buscando compreender e solucionar problemas reais a partir dos dados disponíveis, integrando de forma sólida as ciências da computação e as ciências da saúde. Na prática, é relacionada com a coleta e análise de dados agregados para obtenção de insights e informações importantes. Esses sistemas transformam, organizam e modelam os dados para tirar conclusões e identificar padrões (NETTO, 2021). O Educational Data Science (ciência de dados educacionais) por sua vez, explora estas informações visando aperfeiçoar a compreensão e a qualidade das experiências de aprendizagem. Foi creditada com a promessa de transformar a educação das profissões da saúde, oferecendo abordagens para lidar com dados grandes e significativa complexidade. Geralmente, os dados são utilizados para o desenvolvimento de aplicativos para problemas, usos e contextos específicos (TOLSGAARD, 2020). Em relação ao uso de Data Science na área da educação em saúde, Lobo (2018), enfatiza que a

Endereço: Av. Nereu Ramos 1071

Bairro: Jardim do Molinho

UF: SC

Município: MAFRA

CEP: 89.300-000

Telefone: (47)3641-5500

Fax: (47)3641-5500

E-mail: comitedestica@unc.br



Continuação do Parecer: 5.646.656

Básicas do Projeto	ETO_1979307.pdf	20:00:27		Aceito
Projeto Detalhado / Brochura Investigador	Brochura_projeto_22_08_2022_V2.pdf	22/08/2022 19:59:57	Leandro Stuermer	Aceito
Outros	Carta_Resposta_Parecer_5580463.pdf	22/08/2022 19:57:35	Leandro Stuermer	Aceito
Outros	termo_de_autorizacao_CUSV.pdf	08/07/2022 14:27:14	Leandro Stuermer	Aceito
Outros	termo_de_autorizacao_VERBEM.pdf	08/07/2022 14:27:01	Leandro Stuermer	Aceito
Folha de Rosto	Folha_de_Rosto_final.pdf	06/07/2022 17:07:00	Leandro Stuermer	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	Justificativa_ausencia_TCLE.pdf	06/07/2022 12:16:57	Leandro Stuermer	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:


Não

MAFRA, 15 de Setembro de 2022

Assinado por:
Tadeu Geronasso
(Coordenador(a))

Endereço: Av. Nereu Ramos 1071
Bairro: Jardim do Moinho CEP: 89.300-000
UF: SC Município: MAFRA
Telefone: (47)3641-5500 Fax: (47)3641-5500 E-mail: comitedestica@unc.br

Página 07 de 07

B**Aprobación ética para encuesta de evaluación (trámite colectivo)***[primera y última página]*

**DICTAMEN DEL COMITÉ DE ÉTICA DE LA INVESTIGACIÓN CON
MEDICAMENTOS DE LAS ÁREAS DE SALUD DE VALLADOLID**

Dr F. Javier Álvarez, Secretario Técnico del COMITÉ DE ÉTICA DE LA
INVESTIGACIÓN CON MEDICAMENTOS de las Áreas de Salud de Valladolid

CERTIFICA

En la reunión del CEIm de las ÁREAS DE SALUD DE VALLADOLID del 24 de julio de 2024, se procedió a la evaluación del siguiente proyecto de investigación:

PI-24-475-O	EVALUACIÓN DE MODELOS DE INTELIGENCIA ARTIFICIAL PARA APOYAR LA TOMA DE DECISIONES EN SALUD VISUAL Y OCULAR	I.P.: RAUL MARTIN HERRANZ EQUIPO: LEANDRO STUERMER, SABRINA BRAGA IOBA/UVA
-------------	---	--

A continuación, señalo los acuerdos tomados por el CEIm de las ÁREAS DE SALUD DE VALLADOLID en relación a dicho Proyecto de Investigación:

- El estudio se plantea siguiendo los requisitos legalmente establecidos.
- Se cumplen los requisitos necesarios de idoneidad del protocolo en relación con los objetivos del estudio, y están justificados los riesgos y molestias previsibles para el sujeto.
- Es adecuado el procedimiento para obtener el consentimiento informado (cuando proceda).
- Es adecuado el modo de reclutamiento previsto (cuando proceda).
- La capacidad del investigador, los colaboradores, las instalaciones y medios disponibles, tal y como ha sido informado, son apropiados para llevar a cabo el estudio.

Este CEIm emite **DICTAMEN FAVORABLE** del citado proyecto de investigación, en la reunión celebrada el 24/07/2024 (acta nº14 de 2024) y acepta que dicho proyecto de investigación sea realizado por el investigador principal y su equipo.

Que el CEIm de las Áreas de Salud de Valladolid, tanto en su composición como en sus procedimientos, cumple con las normas de BPC (CPMP/ICH/135/95) y con la legislación vigente que regula su funcionamiento, y que la composición del CEIm de las Áreas de Salud de Valladolid (Hospital Clínico Universitario de Valladolid, Hospital Universitario Río Hortega, Hospital de Medicina, Atención Primaria Área de Salud Valladolid Oeste y Este) es la indicada en el anexo I, teniendo en cuenta que en el caso de que algún miembro participe en el estudio o declare algún conflicto de interés no habrá participado en la evaluación ni en el dictamen de la solicitud de autorización del estudio.



Lo que firmo en Valladolid a 24 de julio de 2024



Dr. F. Javier Álvarez.
CEIm de las Áreas de Salud Valladolid,
Hospital Clínico Universitario de Valladolid,
Hospital Universitario Río Hortega
Hospital de Medina del Campo,
Atención Primaria Área de Salud Valladolid Oeste y Este
Facultad de Medicina, Farmacología,
C/ Ramón y Cajal 7, 47005 Valladolid
alvarez@uva.es jalvarezgo@saludcastillayleon.es
<https://ceimvalladolid.es>
tel.: 983 423077

**Encuesta de evaluación aplicada**

[A= Grupo intervención. B= Grupo control.]

CONSENTIMIENTO INFORMADO

Lo invitamos a participar en el cuestionario “Evaluación de modelos de inteligencia artificial para apoyar la toma de decisiones en salud visual y ocular”, a cargo del investigador Ms. Leandro Stuermer (1) y el Dr. Raúl Martín Herranz (2) que tiene como objetivo comparar el desempeño de un asistente virtual basado en inteligencia artificial (IA), analizar su impacto en la toma de decisiones y conocer la opinión sobre las herramientas tecnológicas aplicadas a la salud visual.

Su participación es VOLUNTARIA y se realizará respondiendo a un cuestionario estructurado, ANÓNIMO y ONLINE. No se le pedirá ningún dato personal ni se registrará ningún tipo de información técnica que no se incluya en sus respuestas. El cuestionario está dirigido a profesionales/estudiantes de ciencias de la visión, con 16 preguntas (15 de opción múltiple / 1 breve descripción), que requieren aproximadamente de 5 a 10 minutos para completarse.

Su participación no le supone ningún gasto ni recibirá remuneración alguna, teniendo derecho a reclamar una indemnización conforme a la ley por los daños y perjuicios que se puedan derivar de su participación. Los riesgos pueden incluir no comprender una pregunta y/o no poder responder adecuadamente, en cualquiera de estas situaciones Usted tendrá la opción de no responder la pregunta. Incluso después de haber consentido en participar, usted aún podrá decidir no completar el cuestionario, teniendo el derecho y la libertad de retirar su consentimiento en cualquier momento, sin necesidad de justificación y sin ningún perjuicio para usted. Sin embargo, una vez enviada su respuesta está no puede ser modificada, anulada ni enmendada al registrarse anónimamente.

Los resultados de la encuesta serán analizados y publicados, pero su identidad no será solicitada, recopilada ni publicada. Tiene la garantía de recibir el resultado de la búsqueda si lo desea. Para cualquier otra información, puede contactar al investigador Leandro Stuermer, Optometrista, al correo electrónico leandrostuermer@gmail.com.

1. Grupo de Investigación en Optometría. Instituto Universitario de Oftalmobiología Aplicada – IOBA. Universidad de Valladolid. Valladolid (España); IDEIA Visão - Instituto de desenvolvimento, investigação e atenção a visão (Brasil); Faculdade de Optometria, Universidade do Contestado - UNC. Canoinhas. (Brasil).

2. Grupo de Investigación en Optometría. Instituto Universitario de Oftalmobiología Aplicada – IOBA. Departamento de Física TAO. Universidad de Valladolid. Valladolid (España);

En vista de estas explicaciones anteriores, ¿usted confirma que es mayor de edad y que está suficientemente informado sobre su participación en esta investigación y que está dispuesto a participar?

SÍ. He leído la información y acepto participar.

NO. No deseo participar.

Sesión I de III - Perfil profesional (5 preguntas)

1. Indique su edad

2. Indique su sexo

Varón

Mujer

Otro

No quiero responder

3. ¿Qué opción define mejor tu situación actual?

Óptico-Optometrista

Oftalmólogo

Estudiante (de Grado en Optometría o Residente de Oftalmología)

Profesor universitario (Optometrista)

Profesor universitario (Oftalmólogo)

Otro, diferente a los anteriores.

No quiero responder

4. ¿Cuánto tiempo tiene de experiencia profesional o como estudiante?

Menos de 5 años

De 5 a 15 años

Más de 15 años

Soy estudiante de último curso, y me falta 1 año o menos para graduarme.

Soy estudiante y me falta más de 1 año para graduarme

No quiero responder

5 ¿En qué país trabajas o estudias? (escriba solo el nombre del PAÍS, o en blanco para no responder)

Argentina

Ecuador

Chile

México

Reino Unido

Brasil

España

Colombia

Puerto Rico

Otro: Indicar

Sección II de III – Presentación de casos clínicos

A partir de la información que se presenta de cada caso, por favor, indique la opción que considera más adecuada em base a sus conocimientos y/o experiencia

6.

A	B
[Caso A]: Hombre de 24 años se queja de disminución de visión de lejos y de cerca, con hiperemia frecuente. La agudeza visual (sin corrección) es de 20/15 (1,3) para lejos y 0,5M (J1) para cerca.	[Caso A]: Hombre de 24 años se queja de disminución de visión de lejos y de cerca, con hiperemia frecuente. La agudeza visual (sin corrección) es de 20/15 (1,3) para lejos y 0,5M (J1) para cerca.
Asistente virtual: <i>Un modelo de IA predice una mayor probabilidad de que este caso tenga 3 problemas distintos: <u>refractivo, oculomotor y patológico</u>.</i>	
Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?	Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?
Problema sólo refractivo	
Problema refractivo y motor.	
Problema refractivo y patológico.	
Problema refractivo, motor y patológico.	
Problema solo motor	
Problema motor y patológico	
Problema sólo patológico	
Ninguno.	
No es mi área o no tengo suficiente información sobre el caso	
No quiero responder	

7.

A	B
[Caso B]: Mujer de 30 años. Se queja de epífora, ardor, fatiga ocular, dolor de cabeza, fotofobia, dolor ocular y mala visión cercana. La agudeza visual (sin corrección) es de 20/20 (1,0) y 0,5 M (J1). Kappa fue positivo. El PPC es de 15cm con objeto real (acomodativo) y luz, y de 20cm con filtro rojo. El Cover Test en visión lejana muestra Orto y 5 dioptrías prismáticas de “X” (foria) en visión próxima.	[Caso B]: Mujer de 30 años. Se queja de epífora, ardor, fatiga ocular, dolor de cabeza, fotofobia, dolor ocular y mala visión cercana. La agudeza visual (sin corrección) es de 20/20 (1,0) y 0,5 M (J1). Kappa fue positivo. El PPC es de 15cm para objetos reales y luz, y de 20cm con filtro rojo. La prueba de cobertura de cercana es 'X' de 5 prismas y Orto para la distancia.
Asistente virtual: <i>Un modelo de IA predice como opción más probable que este caso tenga 2 problemas oculomotores: <u>de vergencia y acomodativo.</u></i>	Usted, con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?
Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?	
Problema de vergencia	
Problema acomodativo	
Problema de vergencia y acomodativo	
Sin problemas oculomotores	
No es mi área o no tengo suficiente información sobre el caso	
No quiero responder	

8.

A

[Caso C]: Mujer de 42 años, hipertensa. Se queja de epífora, dolor de cabeza, fotofobia, así como disminución de visión de lejos y de cerca. La agudeza visual (sin corrección) es de 20/20 (1,0) y 0,5 M (J1). La biomicroscopía de polo anterior mostró telangiectasias e hiperemia leve. La oftalmoscopia mostró patrón ISNT conservado y excavación 0,7.

Asistente virtual: Un modelo de IA predice una mayor probabilidad de que este caso tenga un problema patológico en el polo posterior del ojo.

Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

Problema patológico en el polo anterior

Problema patológico en el polo posterior

Problema patológico en el polo anterior y posterior.

Sin problemas de orden patológico

No es mi área o no tengo suficiente información sobre el caso

No quiero responder

B

[Caso C]: Mujer de 42 años, hipertensa. Se queja de epífora, dolor de cabeza, fotofobia, así como visión de lejos y de cerca. La agudeza visual medida es 20/20 (1,0) y 0,5 M (J1). La biomicroscopía mostró telangiectasias e hiperemia leve. La oftalmoscopia mostró patrón ISNT y excavación 0,7.

Usted, con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

9.

A

[Caso D]: Mujer de 54 años. Se queja de epífora, fotofobia, así como de disminución de la visión de lejos y de cerca. La agudeza visual (sin corrección) es de 20/100 (0,2) y 2M (J6).

Asistente virtual: Un modelo de IA predice una mayor probabilidad de que este caso tenga 2 problemas distintos: refractivo y patológico.

Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

B

[Caso D]: Mujer de 54 años. Se queja de epífora, fotofobia, así como de visión de lejos y de cerca. La agudeza visual medida es 20/100 (0,2) y 2M (J6).

Usted, con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

Problema sólo refractivo

Problema refractivo y motor.

Problema refractivo y patológico.

Problema refractivo, motor y patológico.

Problema solo motor

Problema motor y patológico

Problema sólo patológico

Ninguno.

No es mi área o no tengo suficiente información sobre el caso

No quiero responder

10.

A

[Caso E]: Niño de 10 años que sólo se queja de dolor de cabeza. La agudeza visual (sin corrección) es de 20/20 (1,0) y 0,5 M (J1). El Cover test presenta Orto para distancia y 4 dioptrías prismáticas de 'X' (foria) para cerca. El PPC mide 15cm con objeto real, 16cm con luz y 19cm con filtro rojo.

Asistente virtual: un modelo de IA predice una mayor probabilidad (54%) de que este caso sea un problema de vergencia.

Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

Problema de vergencia

Problema acomodativo

Problema con vergencia y acomodativo

Sin problemas oculomotores

No es mi área o no tengo suficiente información sobre el caso

No quiero responder

B

[Caso E]: La única queja de un niño de 10 años es dolor de cabeza. La agudeza visual medida es 20/20 (1,0) y 0,5 M (J1). En la prueba de cobertura presenta 'X' de 4 prismas para cerca y Orto para distancia. El PPC mide 15cm con objeto real, 16cm con luz y 19cm con filtro rojo.

Usted, con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?

11. En una escala del 1 al 5, donde 1 es confianza mínima y 5 es confianza máxima (o en blanco si no quieres responder).

¿Cuál sería su nivel de confianza (convicción) respecto de su respuesta en la pregunta anterior [caso E]?

1

2

3

4

5

12.

A	B
[Caso F]: Hombre de 63 años que refiere dolor y ardor en los ojos, así como disminución de visión de lejos y de cerca. La agudeza visual (sin corrección) es de 20/40 (0,5) y 2M (J6). La biomicroscopia muestra signos de concreción, secreción e hiperemia. La oftalmoscopia mostró bordes papilares definidos, excavación de 0,3 y una relación arteria-vena de 1:2.	[Caso F]: Un hombre de 63 años se queja de dolor y ardor en los ojos, así como de visión de lejos y de cerca. La agudeza visual medida es 20/40 (0,5) y 2M (J6). La biomicroscopia mostró signos de concreción, secreción e hiperemia. La oftalmoscopia mostró bordes papilares definidos, excavación de 0,3 y una relación arteria-vena de 2:1.
Asistente virtual: <i>Un modelo de IA predice una mayor probabilidad (51%) de que este caso <u>no tenga problemas patológicos</u>.</i>	Usted, con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?
Con sólo esta información, ¿Cuál sería la hipótesis más probable para este caso?	

Problema patológico en el polo anterior

Problema patológico en el polo posterior

Problema patológico en el polo anterior y posterior

Sin problemas de orden patológico

No es mi área o no tengo suficiente información sobre el caso

No quiero responder

13 En una escala del 1 al 5, donde 1 es confianza mínima y 5 es confianza máxima (o en blanco si no quieres responder).

¿Cuál sería su nivel de confianza (convicción) respecto de su respuesta en la pregunta anterior [caso F]?

1

2

3

4

5

Sesión III de III - Percepción y opinión (3 preguntas)

14. Un asistente virtual basado en Inteligencia Artificial, que genere respuestas probabilísticas a situaciones clínicas, podría ser útil para apoyar la toma de decisiones en su actividad profesional

Totalmente de acuerdo

De acuerdo

Ni de acuerdo ni en desacuerdo

En desacuerdo

Totalmente en desacuerdo

No tengo una opinión clara

No quiero responder

15. ¿Cuál es su percepción de confiabilidad en relación a las respuestas de aplicaciones, equipos o herramientas que utilizan algoritmos y modelos desarrollados con apoyo de inteligencia artificial?

Confío totalmente

Confío

No confío, no desconfío

Desconfío

Desconfío totalmente

No tengo una opinión clara

No quiero responder

16. ¿Cómo se sientes cuando piensa en su futuro rol profesional en relación con las tecnologías de salud digital, especialmente el uso de la inteligencia artificial aplicada a la salud de la visión? [Seleccione hasta 3 opciones]

Tranquilo

Preocupado

Motivado

Desmotivado

Neutral/Indiferente

Desanimado

Animado

Pesimista

Optimista

No quiero responder

