

SOPHIA: System for Ophthalmic Image Acquisition, Transmission, and Intelligent Analysis

Oscar-Julián Perdomo-Charry; Andrés-Daniel Pérez; Melissa de-la-Pava-Rodríguez; Hernán-Andrés Ríos-Calixto; Víctor-Alfonso Arias-Vanegas; Juan-Sebastián Lara-Ramírez; Santiago Toledo-Cortés; Jorge-Eliecer Camargo-Mendoza; Francisco-José Rodríguez-Alvira; Fabio-Augusto González-Osorio

Citación: O.-J. Perdomo-Charry, A.-D. Pérez, M. de-la-Pava-Rodríguez, H.-A. Ríos-Calixto, V.-A. Arias-Vanegas, J.-S. Lara-Ramírez, S. Toledo-Cortés, J.-E. Camargo-Mendoza, F.-J. Rodríguez-Alvira, F.-A. González-Osorio, "SOPHIA: System for Ophthalmic Image Acquisition, Transmission, and Intelligent Analysis," *Revista Facultad de Ingeniería*, vol. 29 (54), e11769, 2020.

<https://doi.org/10.19053/01211129.v29.n54.2020.11769>

Recibido: Julio 23, 2020; **Aceptado:** Septiembre 14, 2020;

Publicado: Septiembre 15, 2020

Derechos de reproducción: Este es un artículo en acceso abierto distribuido bajo

la licencia [CC BY](#)



Conflicto de intereses: Los autores declaran no tener conflicto de intereses.

Oscar-Julián Perdomo-Charry; Andrés-Daniel Pérez; Melissa de-la-Pava-Rodríguez; Hernán-Andrés Ríos-Calixto; Víctor-Alfonso Arias-Vanegas; Juan-Sebastián Lara-Ramírez; Santiago Toledo-Cortés; Jorge-Eliecer Camargo-Mendoza; Francisco-José Rodríguez-Alvira; Fabio-Augusto González-Osorio

SOPHIA: System for Ophthalmic Image Acquisition, Transmission, and Intelligent Analysis

Oscar-Julián Perdomo-Charry¹

Andrés-Daniel Pérez²

Melissa de-la-Pava-Rodríguez³

Hernán-Andrés Ríos-Calixto⁴

Víctor-Alfonso Arias-Vanegas⁵

Juan-Sebastián Lara-Ramírez⁶

Santiago Toledo-Cortés⁷

Jorge-Eliecer Camargo-Mendoza⁸

Francisco-José Rodríguez-Alvira⁹

Fabio-Augusto González-Osorio¹⁰

¹ Ph. D. Universidad del Rosario (Bogotá-Distrito Capital, Colombia). oscarj.perdomo@urosario.edu.co. ORCID: [0000-0001-9493-2324](https://orcid.org/0000-0001-9493-2324)

² Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). anperezpe@unal.edu.co. ORCID: [0000-0002-2007-3202](https://orcid.org/0000-0002-2007-3202)

³ Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). medel@unal.edu.co. ORCID: [0000-0001-7357-1080](https://orcid.org/0000-0001-7357-1080)

⁴ Fundación Oftalmológica Nacional (Bogotá-Distrito Capital, Colombia). ORCID: [0000-0002-9422-7112](https://orcid.org/0000-0002-9422-7112)

⁵ Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). viariasv@unal.edu.co. ORCID: [0000-0002-2358-5908](https://orcid.org/0000-0002-2358-5908)

⁶ Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). julara@unal.edu.co. ORCID: [0000-0003-3408-003X](https://orcid.org/0000-0003-3408-003X)

⁷ Ph. D. (c) Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). stoledoc@unal.edu.co. ORCID: [0000-0003-4172-9263](https://orcid.org/0000-0003-4172-9263)

⁸ Ph. D. Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). jecamargom@unal.edu.co. ORCID: [0000-0002-3562-4441](https://orcid.org/0000-0002-3562-4441)

⁹ Fundación Oftalmológica Nacional (Bogotá-Distrito Capital, Colombia). fjrodriguez@fon.org.co. ORCID: [0000-0002-1728-3444](https://orcid.org/0000-0002-1728-3444)

¹⁰ Ph. D. Universidad Nacional de Colombia (Bogotá-Distrito Capital, Colombia). fgonzalezo@unal.edu.co. ORCID: [0000-0001-9009-7288](https://orcid.org/0000-0001-9009-7288)

Abstract

Ocular diseases are one of the main causes of irreversible disability in people in productive age. In 2020, approximately 18% of the worldwide population was estimated to suffer of diabetic retinopathy and diabetic macular edema, but, unfortunately, only half of these people were correctly diagnosed. On the other hand, in Colombia, the diabetic population (8% of the country's total population) presents or has presented some ocular complication that has led to other associated costs and, in some cases, has caused vision limitation or blindness. Eye fundus images are the fastest and most economical source of ocular information that can provide a full clinical assessment of the retinal condition of patients. However, the number of ophthalmologists is insufficient and the clinical settings, as well as the attention of these experts, are limited to urban areas. Also, the analysis of said images by professionals requires extensive training, and even for experienced ones, it is a cumbersome and error-prone process. Deep learning methods have marked important breakthroughs in medical imaging due to outstanding performance in segmentation, detection, and disease classification tasks. This article presents SOPHIA, a deep learning-based system for ophthalmic image acquisition, transmission, intelligent analysis, and clinical decision support for the diagnosis of ocular diseases. The system is under active development in a project that brings together healthcare provider institutions, ophthalmology specialists, and computer scientists. Finally, the preliminary results in the automatic analysis of ocular images using deep learning are presented, as well as future work necessary for the implementation and validation of the system in Colombia.

Keywords: clinical decision support; deep learning; intelligent analysis; ocular diseases; ophthalmic image acquisition; telemedicine.

SOPHIA: Sistema para adquisición, transmisión, y análisis inteligente de imágenes oftálmicas

Resumen

Las enfermedades oculares son una de las principales causas de incapacidad irreversible en personas en edad productiva. En 2020, la población mundial con

retinopatía diabética y edema macular diabético está estimada como el 18% de la población mundial, aproximadamente, desafortunadamente, solo la mitad de estas personas fueron diagnosticadas correctamente. Por otro lado, en Colombia, la población diabética (8% de la población total del país) presenta o ha presentado alguna complicación ocular que ha llevado a otros costos asociados y, en algunos casos, ha provocado limitación de la visión o ceguera. Las imágenes de fondo de ojo son la fuente de información ocular más rápida y económica que puede proveer una valoración clínica del estado de la retina de los pacientes. Sin embargo, el número de oftalmólogos es insuficiente, la atención de estos expertos está limitada a zonas urbanas, y el análisis de dichas imágenes por parte de profesionales requiere una amplia formación; incluso para los más experimentados, es un proceso engorroso y propenso a errores. Los métodos de aprendizaje profundo han marcado avances importantes en imágenes médicas debido al desempeño sobresaliente en tareas de segmentación, detección y clasificación de enfermedades. Este artículo presenta SOPHIA, un sistema basado en el aprendizaje profundo para la adquisición, transmisión, análisis inteligente y soporte de decisiones clínicas para el diagnóstico de enfermedades oculares. El sistema se encuentra en desarrollo activo en un proyecto que reúne a instituciones proveedoras de salud, especialistas en oftalmología e informáticos. Finalmente, los resultados preliminares en el análisis automático de imágenes oculares utilizando el aprendizaje profundo son presentados, y se discute el trabajo futuro necesario para la implementación y validación del sistema en Colombia.

Palabras clave: adquisición de imágenes oftálmicas; análisis inteligente; apoyo a la decisión clínica; aprendizaje profundo; enfermedades oculares; telemedicina.

SOPHIA: Sistema para aquisição, transmissão e análise inteligente de imagens oftálmicas

Resumo

As enfermidades oculares são uma das principais causas de incapacidade irreversível em pessoas em idade produtiva. Em 2020, a população mundial com retinopatía diabética e edema macular diabético está estimada como 18% da

população mundial, aproximadamente, desafortunadamente, só a metade destas pessoas foram diagnosticadas corretamente. Por outro lado, na Colômbia, a população diabética (8% da população total do país) apresenta ou já apresentou alguma complicação ocular que tem levado a outros custos associados e, em alguns casos, tem provocado limitação da visão ou cegueira. As imagens de fundo de olho são a fonte de informação ocular mais rápida e econômica que pode prover uma valoração clínica do estado da retina dos pacientes. Porém, o número de oftalmologistas é insuficiente, a atenção destes expertos está limitada a zonas urbanas, e a análise de tais imagens por parte de profissionais requer uma ampla formação; incluso para os mais experimentados, é um processo complexo e propenso a erros. Os métodos de aprendizagem profunda têm marcado avanços importantes em imagens médicas devido ao desempenho sobressaliente em tarefas de segmentação, detecção e classificação de enfermidades. Este artigo apresenta SOPHIA, um sistema baseado na aprendizagem profunda para a aquisição, transmissão, análise inteligente e suporte de decisões clínicas para o diagnóstico de enfermidades oculares. O sistema encontra-se em desenvolvimento ativo em um projeto que reúne a instituições provedoras de saúde, especialistas em oftalmologia e informáticos. Finalmente, os resultados preliminares na análise automática de imagens oculares utilizando a aprendizagem profunda são apresentados, e discute-se o trabalho futuro necessário para a implementação e validação do sistema na Colômbia.

Palavras chave: aquisição de imagens oftálmicas; análise inteligente; apoio à decisão clínica; aprendizagem profunda; enfermidades oculares; telemedicina.

I. INTRODUCCIÓN

Las imágenes oculares han ido evolucionando continuamente y constituyen una herramienta útil en la atención clínica de pacientes con enfermedades retinianas. En las últimas décadas, el uso de diferentes modalidades ha proporcionado una descripción detallada de enfermedades de la retina. Las diferentes imágenes oculares proporcionan información sobre la anatomía y los cambios funcionales en la retina con imágenes de alta resolución [1].

Adicionalmente, las imágenes oculares son esenciales para el pronóstico, diagnóstico y seguimiento de los pacientes con enfermedades retinianas. Actualmente, las modalidades más utilizadas por los oftalmólogos son la fotografía de fondo de ojo (FP) y la tomografía de coherencia óptica (OCT). La FP presenta una representación 2D de los tejidos semitransparentes retinianos proyectados en un plano de imagen 3D utilizando luz reflejada. Por otro lado, la OCT usa interferometría de luz de baja coherencia para crear una imagen detallada de las capas retiniana y coroidea [2]. Ambas se utilizan ampliamente para la detección y el tratamiento de enfermedades oculares relacionadas con la diabetes, como la retinopatía diabética (DR) y el edema macular diabético (DME). DME y DR son complicaciones responsables de alrededor de 37 millones de casos de ceguera en todo el mundo. Estas enfermedades también son una de las principales causas de pérdida de visión adquirida entre las personas en edad laboral [3].

En todo el mundo, el presupuesto dedicado para enfermedades relacionadas con los trastornos de la visión ha aumentado exponencialmente en los últimos años. Además, el aumento de la esperanza de vida requiere más servicios de atención ocular de las poblaciones, lo que impulsa a los sistemas de salud a brindar una atención adecuada a las poblaciones rurales y remotas [4].

Los métodos basados en aprendizaje profundo para el análisis automático de imágenes oculares han demostrado ser una herramienta valiosa para apoyar la toma de decisiones médicas [5-8]. Además, la sinergia de tele-oftalmología y algoritmos de aprendizaje profundo se considera una solución que ofrece una alternativa adecuada y eficiente, especialmente en enfermedades de la retina, donde las imágenes son útiles para el diagnóstico y el seguimiento médico [9]. Este

artículo presenta una arquitectura llamada SOPHIA, para el diagnóstico de enfermedades oculares. SOPHIA consta de cinco bloques: adquisición, almacenamiento, análisis, acceso y presentación. El sistema admite diferentes tipos de dispositivos de adquisición, en particular dispositivos portátiles y de bajo costo basado en teléfonos inteligentes.

La estructura del artículo está organizada de la siguiente manera: la Sección 2 describe la arquitectura general del sistema. Los resultados son presentados en la Sección 3. La discusión, conclusiones y trabajos futuros son mencionados en la Sección 4. Finalmente, la Sección 5 contiene los agradecimiento y financiación.

II. METODOLOGÍA

SOPHIA es una sigla proveniente del inglés *System for OPHthalmic image acquisition, transmission, and Intelligent Analysis*, siendo un sistema basado en algoritmos de aprendizaje profundo para la gestión de imágenes médicas oftálmicas. Su arquitectura general corresponde a la de un sistema de archivado y transmisión de imágenes (*PACS*), es decir, un sistema que proporciona almacenamiento y acceso a imágenes médicas [10].

Sin embargo, el diseño de SOPHIA obedece a objetivos de diseño particulares: la solución debe centrarse en su bajo costo, usando herramientas de software libre, código de fuente abierta y bajos requisitos de hardware; la solución debe admitir imágenes de dispositivos de imágenes oftálmicas convencionales y dispositivos de adquisición de bajo costo (impresión 3D); el acceso a las imágenes debe soportar diferentes mecanismos, desde la búsqueda de texto convencional de metadatos de imágenes hasta mecanismos de recuperación basados en contenido visual; finalmente, debe proporcionarse una interfaz que admita diferentes tipos de usuarios y plataformas, tanto interfaz web como móvil.

La arquitectura general de SOPHIA se muestra en la Figura 1. La arquitectura está organizada en cinco diferentes bloques: adquisición, almacenamiento, análisis, acceso y presentación.

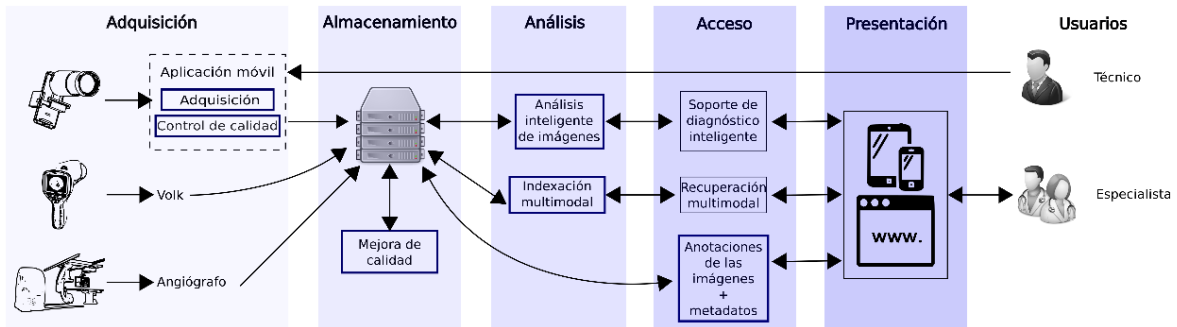


Fig. 1. Diagrama de bloques con la estructura de SOPHIA.

A. Adquisición

Los principales dispositivos usados en los centros oftalmológicos son de las marcas: *Zeiss*, *Optovue*, *Canon*, *Topcom* y *Heidelberg*. Estos dispositivos están limitados por el alto costo asociado, la no portabilidad y limitaciones de fábrica para el análisis posterior de las imágenes. Por otro lado, algunas cámaras portables permiten una fácil adquisición y posterior análisis, pero tienen un costo considerable, las más utilizadas incluyen: *Volk pictor plus*, *Horus Scope* y *Welch Allyn RetinaVue 100 Imager* [10].

B. Almacenamiento

El bloque de almacenamiento corresponde a una base de datos en la nube que almacena imágenes y metadatos. Sin embargo, las imágenes adquiridas con dispositivos móviles son evaluadas para el mejoramiento de la iluminación, contraste y realce de bordes según criterios clínicos.

C. Análisis

Este bloque utiliza métodos para dos propósitos principales: soporte de diagnóstico y análisis de contenido visual/textual para mejorar la recuperación de imágenes [11-14]. El módulo de análisis inteligente de imágenes incluye diferentes modelos de aprendizaje profundo para el diagnóstico de enfermedades oculares. El módulo de indexación multimodal incluye modelos que permiten analizar conjuntamente el contenido visual de la imagen y textual de los metadatos para extraer patrones útiles para la recuperación de información de imágenes basada en el contenido.

D. Acceso

El bloque de acceso proporciona algunos módulos que implementan diferentes funcionalidades del sistema. La etapa de soporte de diagnóstico inteligente proporciona información clínica interpretable adicional para la predicción de la enfermedad. Por otro lado, el uso de algoritmos para recuperar información clínicamente significativa de grandes bases de datos médicas apoya el diagnóstico y la toma de decisiones. Finalmente, la etapa de anotación de imágenes y edición de metadatos permiten incluir nueva información sobre datos clínicos, características locales y globales en el conjunto de datos de imágenes.

E. Presentación

Este bloque corresponde a la interfaz de usuario del sistema, que es una aplicación basada en web que se puede acceder desde un navegador o dispositivos móviles.

III. RESULTADOS

Esta sección presenta los principales resultados obtenidos para la evaluación de calidad, detección de DR, DME y hallazgos clínicos. Las bases de datos, criterios clínicos y los resultados obtenidos fueron validados por médicos de la Fundación Oftalmológica Nacional.

A. Evaluación automática de calidad de imágenes oftálmicas

La evaluación automática de calidad se desarrolló usando el conjunto de imágenes de fondo de ojo proporcionado por *California Healthcare Foundation* y *Kaggle* para la detección de retinopatía diabética [15]. Las imágenes de esta base de datos fueron clasificadas por expertos como: imágenes con calidad aceptable e imágenes rechazadas (problema binario) [16], y en un problema multiclase con etiquetas de imágenes de buena, usable y mala calidad respectivamente [17].

La arquitectura del modelo propuesto contiene una serie de 5 bloques de capas convolucionales y agrupación máxima con diferentes filtros 16, 32, 64, 64 y 64, y con tamaños de kernel de 11x11, 9x9, 7x7, 6x6 y 6x6 respectivamente. Finalmente,

tres capas densas con 256 y 64 neuronas en las dos primeras capas, mientras que la última capa utiliza el número de clases, como se presenta en la Figura 2.

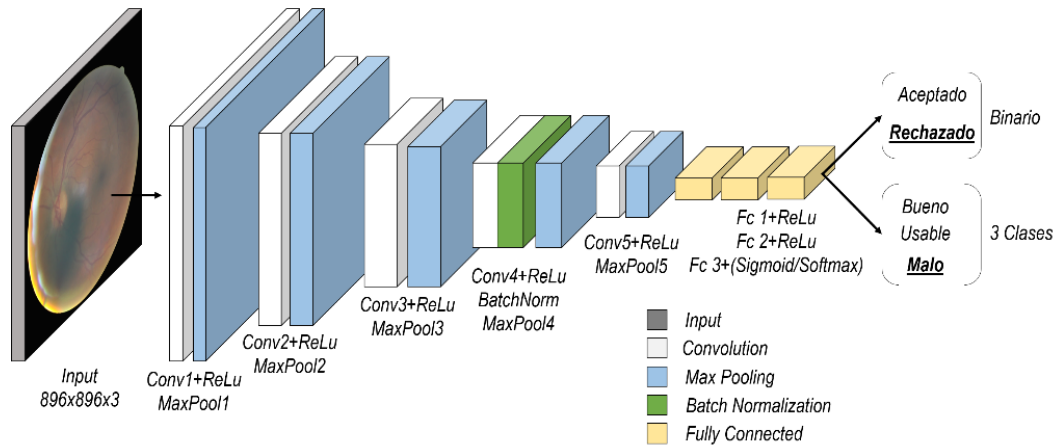


Fig. 2. Modelo de aprendizaje profundo para evaluación de calidad de imágenes.

Los resultados obtenidos en conjuntos de prueba son presentados en la Tabla 1.

Tabla 1. Medidas de desempeño para los modelos de evaluación de calidad de imágenes de fondo de ojo.

Conjunto de datos	Sensibilidad	Especificidad	Exactitud
<i>Binario</i>	94.21%	88.53%	91.17%
<i>Multiclase</i>	85.65%	85.64%	85.64%

B. Modelos para la detección de retinopatía diabética

Los modelos para la detección de retinopatía diabética se desarrollaron empleando dos conjuntos de datos: el conjunto de datos de prueba de *Kaggle* que consta de alrededor de 88000 imágenes de fondo de ojo y contiene la clasificación numérica: 0 para personas sanas, y de 1-5 para retinopatía leve, moderada, grave y proliferativa respectivamente [15]. El segundo conjunto es Messidor-2 [18], con 1748 imágenes de fondo de ojo de un programa de investigación francés y etiquetas binarias para DR referenciable y no referenciable.

La arquitectura *InceptionV3* fue entrenada y ajustada usando los pesos pre-entrenados de *ImageNet* [20], como se presenta en la Figura 3.

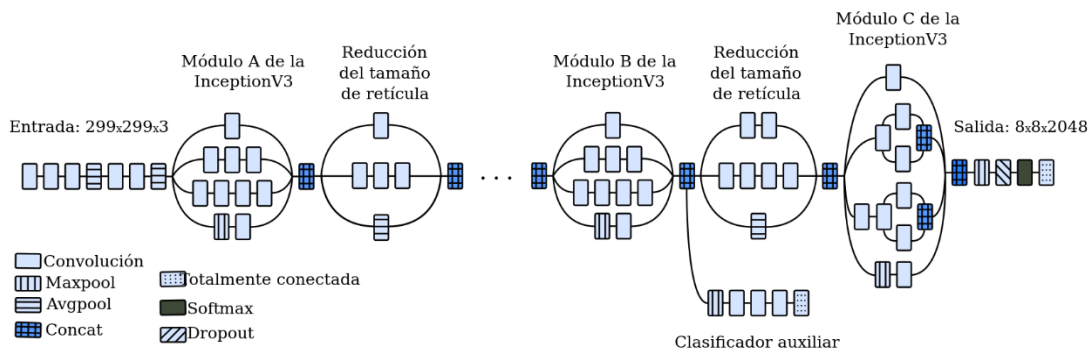


Fig. 3. Arquitectura usada para la detección automática de DR [19].

El modelo usa una tasa de aprendizaje baja (LR) para realizar un ajuste fino con la partición de entrenamiento del conjunto de *Kaggle*. Cada imagen se asoció una etiqueta de 0 para pacientes sanos o no referible, y 1 a un paciente con cualquier diagnóstico de DR o referible. Inicialmente se extraen características usando la *InceptionV3* pre-entrenada con *ImageNet*. Estas características se usan como entrada del modelo de clasificación, sobre el cual se realizó una exploración sistemática para determinar los mejores hiper-parámetros, en nuestro caso una tasa de aprendizaje $LR = 1 \times 10^{-3}$ y el tamaño del *batch* de 32. Finalmente, se realiza un ajuste fino de los pesos pre-entrenados de los dos últimos bloques de la arquitectura de la *InceptionV3* durante 300 épocas, usando como algoritmo de optimización el descenso estocástico de gradiente (SGD), con $LR = 1 \times 10^{-5}$, un momento de 0,9, la pérdida empleada fue *categorical cross-entropy*, y un tamaño del *batch* de 32. De esta forma, se obtuvo un AUC de 0,92, una sensibilidad de 89.74%, una especificidad de 92.44% y una exactitud de 90.10% usando el conjunto Messidor-2.

C. Resultados obtenidos en la detección de EMD y hallazgos clínicos

El modelo propuesto se entrenó usando una red VGG para clasificar las imágenes con DME moderado, usando un optimizador adaptativo Adam, con una $LR = 1 \times 10^{-5}$ y un tamaño de *batch* de 2. El número de capas densas y el número de nodos por capas del clasificador fue explorado en una búsqueda sistemática usando 25 épocas y una función de entropía cruzada binaria para modelar la pérdida. Los resultados con 2 capas densas, y con un número de unidades de 4096 y 512

presentaron los mejores resultados en entrenamiento y validación. El mejor modelo fue evaluado con el conjunto de prueba, los resultados se presentan en la Tabla 2.

Tabla 2. Exactitud en la detección de DME leve y otros hallazgos clínicos de DR.

Hallazgos Clínicos	Exactitud en el conjunto de prueba
<i>DME leve</i>	75,98%
<i>He</i>	91,2%
<i>CWS</i>	91,63%
<i>A</i>	90,2%

IV. DISCUSIÓN Y CONCLUSIONES

Los métodos de aprendizaje profundo implementados han conseguido un buen desempeño para la evaluación de calidad o la mejora de imágenes de fondo de ojo. Sin embargo, la mejora de imágenes tomadas con dispositivos móviles es un desafío aún [21]. Además, el aprendizaje profundo ofrece el mejor desempeño para la descripción de contenido visual en comparación con otros métodos [22], por lo cual, su aplicación en recuperación de información oftalmológica es una oportunidad de investigación prometedora [23].

Las bases de datos oftalmológicas poseen información adicional que no se explota por completo como: datos clínicos, reportes de diagnóstico, u otros datos que podrían ser incluidos para mejorar el desempeño de los modelos. En este aspecto, existe la necesidad de sistemas multimodales que permitan explotar de forma efectiva la información conjunta entre distintas fuentes de información.

Existe un gran potencial para el diseño e implementación de sistemas de bajo costo basados en técnicas de aprendizaje de máquina y profundo en países de bajos ingresos y en desarrollo. El sistema propuesto combina una adquisición con un dispositivo de bajo costo y métodos de visión por computadora con los más altos requisitos clínicos para garantizar un diagnóstico médico preciso en zonas remotas y de difícil acceso. La implementación y validación futura de este tipo de sistemas en apoyo con personal clínico representan grandes desafíos que potencialmente podrían ayudar a reducir la baja cobertura de los sistemas de salud pública, la falta de servicios especializados y el alto costo de los exámenes médicos especializados.

AGRADECIMIENTOS

Los autores agradecen el apoyo de MinCiencias con el proyecto de investigación “Detección Temprana de daño ocular en Diabéticos usando un sistema de Inteligencia Artificial en Imágenes de Fondo de Ojo” 1101-807-63563 y a la Universidad Nacional de Colombia por el apoyo en el proyecto “Clasificación de retinopatía diabética y edema macular diabético en imágenes de fondo de ojo mediante redes neuronales convolucionales” número 202010029118. Este trabajo fue parcialmente financiado por un Google Research Award.

CONTRIBUCIÓN DE LOS AUTORES

Oscar-Julián Perdomo-Charry; Andrés-Daniel Pérez; Melissa de-la-Pava-Rodríguez; Víctor-Alfonso Arias-Vanegas; Juan-Sebastián Lara-Ramírez; Santiago Toledo-Cortes: Análisis formal, Investigación, Metodología y redacción – borrador original.

Hernán-Andrés Ríos-Calixto; Francisco-José Rodríguez-Alvira: Conceptualización, Investigación y Validación.

Jorge-Eliecer Camargo-Mendoza; Fabio-Augusto González-Osorio: Conceptualización, Metodología, Supervisión y redacción-revisión y edición.

REFERENCIAS

- [1] American Diabetes Association, “Classification and diagnosis of diabetes,” *Diabetes Care*, vol. 39 (1), S13-S22, 2016. <https://doi.org/10.2337/dc16-S005>
- [2] M. Abramoff, M. Garvin, and M. Sonka, “Retinal imaging and image analysis,” *IEEE reviews in biomedical engineering*, vol. 3, pp. 169-208, 2010. <https://doi.org/10.1109/RBME.2010.2084567>
- [3] J. Köberlein, K. Beifus, C. Schaffert, and R. Finger, “The economic burden of visual impairment and blindness: a systematic review,” *BMJ open*, vol. 3 (11), e003471, 2013. <https://doi.org/10.1136/bmjopen-2013-003471>
- [4] G. Labiris, E. Panagiotopoulou, and V. Kozobolis, “A systematic review of teleophthalmological studies in Europe,” *International journal of ophthalmology*, vol. 11 (2), pp. 314-325, 2018. <https://doi.org/10.18240/ijo.2018.02.22>
- [5] R. Gargeya, and T. Leng, “Automated identification of diabetic retinopathy using deep learning,” *Ophthalmology*, vol. 124 (7), pp. 962-969, 2017. <https://doi.org/10.1016/j.ophtha.2017.02.008>
- [6] S. Otálora, O. Perdomo, F. González, and H. Müller, “Training deep convolutional neural networks with active learning for exudate classification in eye fundus images,” In *Intravascular Imaging and Computer*

Oscar-Julían Perdomo-Charry; Andrés-Daniel Pérez; Melissa de-la-Pava-Rodríguez; Hernán-Andrés Ríos-Calixto; Víctor-Alfonso Arias-Vanegas; Juan-Sebastián Lara-Ramírez; Santiago Toledo-Cortés; Jorge-Eliecer Camargo-Mendoza; Francisco-José Rodríguez-Alvira; Fabio-Augusto González-Osorio

- Assisted Stenting, and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis*, pp. 146-154, 2017. https://doi.org/10.1007/978-3-319-67534-3_16
- [7] C. Lam, C. Yu, L. Huang, and D. Rubin, "Retinal lesion detection with deep learning using image patches," *Investigative ophthalmology & visual science*, vol. 59 (1), pp. 590-596, 2018. <https://doi.org/10.1167/iovs.17-22721>
- [8] O. Perdomo, S. Otálora, F. Rodríguez, J. Arévalo, and F. González, "A novel machine learning model based on exudate localization to detect diabetic macular edema," in *Proceedings of the Ophthalmic Medical Image Analysis Third International Workshop*, pp. 137-144, 2016. <https://doi.org/10.17077/omia.1057>
- [9] B. Host, A. Turner, and J. Muir, "Real-time teleophthalmology video consultation: an analysis of patient satisfaction in rural Western Australia," *Clinical and Experimental Optometry*, vol. 101 (1), pp. 129-134, 2018. <https://doi.org/10.1111/cxo.12535>
- [10] J. Micheletti, A. Hendrick, F. Khan, D. Ziemer, and F. Pasquel, "Current and next generation portable screening devices for diabetic retinopathy," *Journal of diabetes science and technology*, vol. 10 (2), pp. 295-300, 2016. <https://doi.org/10.1177/1932296816629158>
- [11] W. Alyoubi, W. Shalash, and M. Abulkhair, "Diabetic retinopathy detection through deep learning techniques: A review," *Informatics in Medicine Unlocked*, vol. 20, e100377, 2016. <https://doi.org/10.1016/j.imu.2020.100377>
- [12] K. Stebbins, "Diabetic Retinal Examinations in Frontline Care Using RetinaVue Care Delivery Model," *Point of Care*, vol. 18 (1), pp. 37-39, 2019. <https://doi.org/10.1097/POC.000000000000183>
- [13] O. Perdomo, J. Arévalo, and F. González, "Convolutional network to detect exudates in eye fundus images of diabetic subjects," in *12th International Symposium on Medical Information Processing and Analysis*, 2017, e101600T. <https://doi.org/10.1117/12.2256939>
- [14] O. Perdomo, V. Andrearczyk, F. Meriaudeau, H. Müller, and F. González, "Glaucoma diagnosis from eye fundus images based on deep morphometric feature estimation," in *Computational pathology and ophthalmic medical image analysis*, pp. 319-327, 2018. https://doi.org/10.1007/978-3-030-00949-6_38
- [15] B. Graham, "Kaggle diabetic retinopathy detection competition report," Master Thesis, University of Warwick, United Kingdom, 2015.
- [16] K. Zhou, Z. Gu, A. Li, J. Cheng, S. Gao, and J. Liu, "Fundus image quality-guided diabetic retinopathy grading," in *Computational Pathology and Ophthalmic Medical Image Analysis*, pp. 245-252, 2018. https://doi.org/10.1007/978-3-030-00949-6_29
- [17] H. Fu, B. Wang, J. Shen, S. Cui, Y. Xu, J. Liu, and L. Shao, "Evaluation of retinal image quality assessment networks in different color-spaces," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 48-56, 2019. https://doi.org/10.1007/978-3-030-32239-7_6
- [18] E. Decencièrre, X. Zhang, G. Cazuguel, B. Lay, B. Cochener, C. Trone, P. Gain, R. Ordonez, P. Massin, A. Erginay, B. Charton and J-C. Klein, "Feedback on a publicly distributed image database: the Messidor database," *Image Analysis & Stereology*, vol. 33 (3), pp. 231-234, 2014. <https://doi.org/10.5566/ias.1155>
- [19] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2818-2826, 2016. <https://doi.org/10.1109/CVPR.2016.308>

- [20] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. Berg and L. Fei-Fei, "Imagenet large scale visual recognition challenge," *International journal of computer vision*, vol. 115 (3), pp. 211-252, 2015. <https://doi.org/10.1007/s11263-015-0816-y>
- [21] T. Vu, C. Van Nguyen, T. Pham, T. Luu, and C. Yoo, "Fast and efficient image quality enhancement via desubpixel convolutional neural networks," in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018. https://doi.org/10.1007/978-3-030-11021-5_16
- [22] J. Wan, D. Wang, S. Hoi, P. Wu, J. Zhu, Y. Zhang, and J. Li, "Deep learning for content-based image retrieval: A comprehensive study," in *Proceedings of the 22nd ACM international conference on Multimedia*, pp. 157-166, 2014. <https://doi.org/10.1145/2647868.2654948>
- [23] Y. Cao, S. Steffey, J. He, D. Xiao, C. Tao, P. Chen, and H. Müller, "Medical image retrieval: a multimodal approach," *Cancer informatics*, vol. 13, e14053, 2014. <https://doi.org/10.4137/CIN.S14053>