

Universidad Autónoma del Caribe

Facultad de Ingeniería

Programa de Ingeniería Electrónica y Telecomunicaciones



Construcción y Evaluación de un modelo de Red Neuronal Convolutiva (CNN)

Para la Detección y Clasificación de la Retinopatía Diabética

José Alejandro Cuello Navarro

Carlos Eduardo Barraza Peña

Barranquilla, Colombia

2021

Construcción y Evaluación de un modelo de Red Neuronal Convolutacional (CNN)
Para la Detección y Clasificación de la Retinopatía Diabética

José Alejandro Cuello Navarro

Carlos Eduardo Barraza Peña

Trabajo de grado presentado para optar el título de
Ingeniero Electrónico y en Telecomunicaciones

Director

José Escorcía Gutiérrez, PhD

Co-Director

Meglys Pérez, Msc

Universidad Autónoma del Caribe

Facultad de Ingeniería

Programa de Ingeniería Electrónica y Telecomunicaciones

Barranquilla, Colombia

2021

Resumen

La retinopatía diabética (RD) es la enfermedad ocular diabética más común en todo el mundo y una de las principales causas de ceguera en la población de 20 a 65 años. El número de pacientes diabéticos aumentará a 552 millones en 2034, según la Federación Internacional de Diabetes (FID). Gracias a la evolución alcanzada por técnicas informáticas como la inteligencia artificial (*Artificial Intelligence, AI*) y el aprendizaje profundo (*Deep Learning, DL*), en la actualidad han aumentado las oportunidades de detectar la RD en sus primeras fases. Esto significa que aumentarán las posibilidades de que una persona se recupere de la enfermedad y la probabilidad de pérdida de la visión en los pacientes disminuirá en un futuro.

En este trabajo de investigación abordamos la tarea de aportar una solución a dicho problema y, en primera medida, hacemos un extenso estudio del estado del arte en el que se comprueba el avance alcanzado por autores de otras partes del mundo en esta área. Luego proponemos un conjunto de algoritmos que conforman el sistema completo, el cual ejecutará la tarea de detección y clasificación de la RD de forma automatizada usando redes pre entrenadas, creadas para tareas de procesamiento y clasificación de imágenes, en unión con un clasificador final personalizado. En nuestro sistema hacemos uso de la técnica del aprendizaje por transferencia (*Transfer Learning*) y añadimos un bloque personalizado de capas densas sobre las redes pre entrenadas para realizar las predicciones y validar los resultados alcanzados, comparándolos con los resultados alcanzados en el estado del arte. Los modelos de DL fueron entrenados y probados sobre el conjunto de datos de la Sociedad de Tele-Oftalmología de Asia Pacífico (APTOS, *por sus siglas en inglés*) 2019.

Los modelos seleccionados en nuestro enfoque preliminar fueron ResNet50, Xception, VGG16, EfficientNetB0 y DenseNet121, tomamos dichos modelos para hacer una comparativa inicial con otros trabajos publicados en el estado del arte y validar si los resultados alcanzados por nosotros eran similares para así considerar si nuestra propuesta pudiese considerarse apropiada para esta tarea de detección de la RD. Se utilizaron técnicas de aumento de datos para hacer los modelos más robustos y superar el problema del sobreajuste. De estas pruebas la red que mejor rendimiento tuvo fue EfficientNetB0 con un resultado tope en exactitud de predicción de 96.86%, una precisión de 98.15%, una sensibilidad de 95.67%, una especificidad de 98.14%, un puntaje F1 de 96.89%, un coeficiente kappa de 93.77% y un área bajo la curva de 96.9%. Con estos resultados se hizo la respectiva comparativa y se constató que, efectivamente, los resultados alcanzados por nosotros superaron a la mayoría de los resultados logrados por autores del estado del arte. En el enfoque final proponemos no solo un sistema de detección de la RD, sino que también abordamos el área de la clasificación de la RD según el nivel de severidad de esta, de acuerdo con lo signos y características detectadas por las redes neuronales pre entrenadas junto con nuestro clasificador final. Para esta tarea usamos las redes pre entrenadas de Xception, VGG16, VGG19, DenseNet121, DenseNet169, InceptionV3, ResNet50, ResNet101, InceptionResNetV2, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3. No incursionamos usando más redes debido a las limitantes de memoria RAM y GPU que nos ofrecía el entorno de desarrollo que usamos para esta investigación (Google Colaboratory). De igual forma se utilizaron técnicas de aumento de datos para mejorar la calidad del entrenamiento y no tener problemas con el sobreajuste. Con este enfoque y por medio de la red DenseNet169 logramos aumentar todas las métricas alcanzadas en la tarea de detección, logrando una exactitud de predicción de 98.72%, una precisión 98.21%, una sensibilidad de 99.28%, una especificidad

de 98.14%, un puntaje F1 de 98.74%, un coeficiente Kappa de 97.43% y un área bajo la curva de 98.71%. Estas métricas superan en su totalidad a las presentadas en el estado del arte, mostrando la robustez de la red para tareas de detección.

Para el caso de la tarea de clasificación de la RD los mejores resultados fueron obtenidos con la red de VGG16 con una exactitud de predicción de 83.52%, una precisión de 82.68%, sensibilidad de 83.52%, puntaje F1 de 82.52% y coeficiente Kappa de 74.71%. Estos resultados fueron comparados por los trabajos disponibles en el estado del arte que se enfocaron en el área de clasificación de la RD y comprobamos que superamos al 90% de los resultados disponibles del estado del arte y nos encontramos muy cercanos al valor máximo alcanzado con una diferencia de exactitud de solo 0,79%. Esto es un logro considerable teniendo en cuenta el grado de complejidad de las redes presentadas en el estado del arte y los recursos computacionales de los que ellos dispusieron.

Por ultimo hacemos una validación en los conjunto de imágenes de MESSIDOR y MESSIDOR-2, confirmamos que nuestro sistema es congruentes con los resultados arrojados pero cabe resaltar que para el caso de MESSIDOR-2 no incluye etiquetas oficiales por lo que fueron obtenidas de terceros y para el caso de MESSIDOR la cantidad de imágenes es bastante pequeña para que el entrenamiento de la red logre resultados iguales a los de APTOS, consideramos entonces que estos dos factores influyeron para que la red no presentara resultados extremadamente favorables con estas dos bases de datos, pero que de todas formas logran el objetivo de detectar y clasificar la RD en imágenes de retina.

Abstract

Diabetic retinopathy (DR) is the most common diabetic eye disease worldwide and a leading cause of blindness in the population aged 20 to 65 years. The number of diabetic patients will increase to 552 million by 2034, according to the International Diabetes Federation (IDF). Thanks to the evolution achieved by computing techniques such as Artificial Intelligence (AI) and Deep Learning (DL), the chances of detecting DR in its early stages have now increased. This means that the chances of a person recovering from the disease will increase and the probability of vision loss in patients will decrease in the future.

In this research work we address the task of providing a solution to such a problem and, first of all, we make an extensive survey of the state of the art in which we check the progress achieved by authors from other parts of the world in this area. Then we propose a set of algorithms that make up the complete system, which will execute the DR detection and classification task in an automated way using pre-trained networks, created for image processing and classification tasks, in conjunction with a final custom classifier. In our system we make use of the Transfer Learning technique and add a customized block of dense layers on top of the pre-trained networks to perform the predictions and validate the results achieved, comparing them with the results achieved in the state of the art. The DL models were trained and tested on the Asia Pacific Tele-Ophthalmology Society (APTOS) 2019 dataset.

The models selected in our preliminary approach were ResNet50, Xception, VGG16, EfficientNetB0 and DenseNet121, we took those models to make an initial comparison with other published work in the state of the art and validate whether the results achieved by us were

similar in order to consider whether our approach could be considered appropriate for this DR detection task. Data augmentation techniques were used to make the models more robust and overcome the overfitting problem. Of these tests the best performing network was EfficientNetB0 with a top result in prediction accuracy of 96.86%, a precision of 98.15%, a sensitivity of 95.67%, a specificity of 98.14%, an F1 score of 96.89%, a kappa coefficient of 93.77% and an area under the curve of 96.9%. With these results, the respective comparison was made and it was found that, indeed, the results achieved by us exceeded most of the results achieved by authors in the state of the art. In the final approach we propose not only a DR detection system, but we also address the area of DR classification according to the severity level of DR, according to the signs and features detected by the pre-trained neural networks together with our final classifier. For this task we used the pre-trained networks of Xception, VGG16, VGG19, DenseNet121, DenseNet169, InceptionV3, ResNet50, ResNet101, InceptionResNetV2, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3. We did not use more networks due to the RAM and GPU limitations offered by the development environment we used for this research (Google Colaboratory). Similarly, data augmentation techniques were used to improve the quality of training and to avoid problems with overfitting. With this approach and by means of the DenseNet169 we managed to increase all the metrics achieved in the detection task, achieving a prediction accuracy of 98.72%, a precision of 98.21%, a sensitivity of 99.28%, a specificity of 98.14%, an F1 score of 98.74%, a Kappa coefficient of 97.43% and an area under the curve of 98.71%. These metrics outperform all those presented in the state of the art, showing the robustness of the network for detection tasks.

For the case of the DR classification task the best results were obtained with the VGG16 network with a prediction accuracy of 83.52%, a precision of 82.68%, sensitivity of 83.52%, F1 score of 82.52% and Kappa coefficient of 74.71%. These results were compared by the available state of the art works that focused on the area of DR classification and we found that we exceeded 90% of the available state of the art results and were very close to the maximum value achieved with an accuracy difference of only 0.79%. This is a considerable achievement considering the degree of complexity of the networks presented in the state of the art and the computational resources available to them.

Finally we make a validation on the set of images of MESSIDOR and MESSIDOR-2, we confirm that our system is congruent with the results obtained but it should be noted that in the case of MESSIDOR-2 does not include official labels so they were obtained from third parties and in the case of MESSIDOR the number of images is quite small for the training of the network to achieve results equal to those of APTOS, We consider then that these two factors influenced the network not to present extremely favorable results with these two databases, but that they still achieve the objective of detecting and classifying DR in retinal images.

Nota de Aceptación

Presidente del Jurado

Jurado

Jurado

Barranquilla, 7 de Mayo de 2021

Dedicatoria

En primer momento, dedicamos esta tesis a Dios, por habernos brindado vida y salud tanto física como mental para poder ejecutar y culminar nuestra carrera profesional y este trabajo de investigación de forma satisfactoria. Adicionalmente porque sin su ayuda ni voluntad nada de esto hubiese sido posible.

Finalmente, dedicamos este trabajo de investigación a nuestros padres que durante todo el tiempo de nuestra estancia en la universidad nos brindaron tanto su apoyo emocional como económico y nos alentaron en todo momento para que diéramos lo mejor de sí y termináramos esta tesis con éxito.

Agradecimientos

Le agradecemos en primera instancia a nuestro Dios Todopoderoso quien nos ha permitido llegar hasta este punto de nuestras vidas, así mismo a nuestros padres, porque gracias a todo el apoyo que nos han brindado hemos alcanzado este gran logro.

Agradecemos a nuestro profesor, el Ingeniero José Escorcía, quien ha sabido orientarnos y motivado en la realización de este proyecto. Por último, agradecemos al Ingeniero Kevin Velásquez quien nos ayudó a adentrarnos en el ámbito de la Inteligencia Artificial.

Tabla de Contenido

INTRODUCCIÓN	1
Motivación	1
Objetivos	4
Objetivo General	4
Objetivos Específicos	4
Contribuciones	4
Estructura del documento	6
ESTADO DEL ARTE	7
Aspectos generales de la retinopatía diabética	8
Etapas de la retinopatía diabética	10
Grados de la Retinopatía Diabética	12
Marco general para los procesos de detección de la RD	13
Conjuntos de imágenes oculares (Datasets)	15
Métricas de rendimiento	18
Extracción de características y métodos de Deep Learning como herramienta para el diagnóstico automatizado de la Retinopatía Diabética	20
ENFOQUE PRELIMINAR DEL PROYECTO (DETECCIÓN DE LA RETINOPATÍA DIABÉTICA)	31
Entorno de trabajo	31
Descripción y procesamiento del conjunto de imágenes	31
Metodología propuesta	34
Resultados	38

METODOLOGÍA PARA LA ELABORACIÓN DE LA RED NEURONAL CONVOLUCIONAL FINAL (DETECCIÓN Y CLASIFICACIÓN DE LA RETINOPATÍA DIABÉTICA)	44
Descripción y procesamiento del conjunto de imágenes	44
Metodología propuesta.....	45
Resultados	49
Clasificación de la Retinopatía Diabética	49
Detección de la Retinopatía Diabética	52
Pruebas adicionales con otros conjuntos de imágenes.....	55
CONCLUSIONES	63
REFERENCIAS	66

Lista de Figuras

Figura 1. Visión de una persona sana vs Visión de una persona con retinopatía diabética.....	2
Figura 2. Imagen de la retina con sus patologías.....	9
Figura 3. Imágenes típicas de fondo de retina: (a) Retina normal, (b) Retina en fase media RDNP, (c) Fase moderada RDNP, (d) Fase severa RDNP, (e) Retinopatía diabética proliferativa (RDP).....	11
Figura 4. Modelo de CNN aplicado a las imágenes de retina.....	15
Figura 5. Imágenes antes y después de pasar por el algoritmo de procesamiento.....	33
Figura 6. Distribución del conjunto de imágenes.....	34
Figura 7. Diagramas de bloque con la estructura de la red.....	36
Figura 8. Ilustración del modelo general para la detección de la RD usando técnicas de Aprendizaje Profundo.....	37
Figura 9. Matriz de confusión obtenida con ResNet50 en el proceso de detección de la RD con conjunto de prueba.....	39
Figura 10. Matriz de confusión obtenida con Xception en el proceso de detección de la RD con conjunto de prueba.....	40
Figura 11. Matriz de confusión obtenida con VGG16 en el proceso de detección de la RD con conjunto de prueba.....	40
Figura 12. Matriz de confusión obtenida con DenseNet121 en el proceso de detección de la RD con conjunto de prueba.....	41
Figura 13. Matriz de confusión obtenida con EfficientNetB0 en el proceso de detección de la RD con conjunto de prueba.....	41
Figura 14. Imágenes antes y después del procesamiento con CLAHE.....	46
Figura 15. Diagrama de construcción de la red.....	47
Figura 16. Diagrama de flujo con el nuevo enfoque seguido para la detección y clasificación de la RD.....	48
Figura 17. Matriz de confusión para la clasificación de la RD haciendo uso de la red VGG16.....	51
Figura 18. Matriz de confusión obtenida en la detección de la RD con DenseNet169.....	54

Figura 19. Matriz de confusión para la clasificación de la RD con imágenes de MESSIDOR haciendo uso de la red EfficientNetB2.....	58
Figura 20. Matriz de confusión para la clasificación de la RD con imágenes de MESSIDOR-2 haciendo uso de la red DenseNet169.....	58
Figura 21. Matriz de confusión para la detección de la RD con imágenes de MESSIDOR haciendo uso de la red EfficientNetB2.....	61
Figura 22. Matriz de confusión para la detección de la RD con imágenes de MESSIDOR-2 haciendo uso de la red DenseNet169.....	61

Lista de Tablas

Tabla 1. Clasificación de grados de la retinopatía diabética.....	12
Tabla 2. Métricas de rendimiento más comunes en Deep Learning.....	19
Tabla 3. Resultados para la detección de la RD con el conjunto de imágenes de APTOS en nuestro enfoque preliminar.....	39
Tabla 4. Comparativa de resultados con trabajos similares del estado del arte.....	43
Tabla 5. Resultados de los modelos evaluados para la clasificación de la RD.....	50
Tabla 6. Resultados de los modelos propuestos en el estado del arte para la clasificación de la RD.....	51
Tabla 7. Resultados de los modelos evaluados para la detección de la RD con el nuevo enfoque.....	53
Tabla 8. Resultados de los modelos propuestos en el estado del arte para la detección de la RD.....	54
Tabla 9. Resultados de los modelos evaluados para la clasificación de la RD usando las imágenes de MESSIDOR.....	56
Tabla 10. Resultados de los modelos evaluados para la clasificación de la RD usando las imágenes de MESSIDOR-2.....	57
Tabla 11. Resultados de los modelos evaluados para la detección de la RD usando las imágenes de MESSIDOR.....	59
Tabla 12. Resultados de los modelos evaluados para la detección de la RD usando las imágenes de MESSIDOR-2.....	60

Introducción

Motivación

La visión es el sentido al cual más uso le damos en el día a día, sin este o con alguna complicación en él, el tiempo que necesitaríamos para realizar las actividades diarias se vería incrementado en gran manera, no podríamos apreciar correctamente los colores de la naturaleza, la cara de nuestros familiares, en conclusión, todo lo que nos rodea. Este dilema de no poder ver bien lo sufren muchas personas actualmente, incluso personas jóvenes, no existe edad para las complicaciones relacionadas con la salud de los ojos y la visión.

El ojo es el órgano sensorial responsable de nuestra vista y se compone de varias partes, algunas de ellas son la pupila, el cristalino, el iris, la córnea y la retina. Ahora bien, la retina es la parte del ojo en donde se manifiestan la mayoría de patologías producidas por enfermedades y complicaciones derivadas de otras enfermedades relacionadas a la visión, el globo ocular y el sistema circulatorio. (Mittal & Rajam, 2020)

Una de estas enfermedades es la Retinopatía Diabética (RD), la cual según Scanlon, (2019) se refiere a la patología de los capilares, arteriolas y vénulas de la retina, y los efectos posteriores de fuga u oclusión de los vasos pequeños. Los cambios que ocurren dentro de los capilares de la retina incluyen engrosamiento de la membrana basal, disfunción de las células epiteliales (pérdida de las uniones epiteliales estrechas), pérdida de células endoteliales, aumento de la permeabilidad capilar, debilitamiento capilar, muerte de las células del músculo liso, oclusión capilar y formación de micro aneurismas. En la [Figura 1](#) se puede observar cómo ve una persona con RD su entorno.

Figura 1.

a) Visión de una persona sana, b) Visión de una persona con retinopatía diabética.



a)



b)

Fuente: Tomado de <https://www.tuoptometrista.com/salud-visual-para-mayores/problemas-oftalmologicos-en-la-vision-de-los-mayores/>

Según Drankowska et al., (2019) la retinopatía sigue siendo una de las complicaciones microvasculares más debilitantes de la diabetes y la principal causa de ceguera adquirida que afecta a aproximadamente 4,2 millones de personas en todo el mundo, con proyecciones de hasta 191 millones de personas afectadas para 2030 en todo el mundo.

Según Cuello Navarro et al., (2020), además de ser una complicación de la diabetes que afecta los ojos, es una enfermedad progresiva que se diagnostica de acuerdo con algunas anomalías clínicas de difícil detección, debido que es asintomática hasta altas etapas del desarrollo de la enfermedad, y si no se realiza un tratamiento adecuado evoluciona en una patología mayor conocida como edema macular diabético que podría conllevar a la pérdida irreversible de la visión.

Es por eso que la principal motivación de este trabajo de investigación reside en que esta enfermedad se vuelve incurable en etapas avanzadas, por lo que el diagnóstico precoz es importante, tal como lo define Asiri et al., (2019). Actualmente una persona necesita esperar mucho tiempo desde que va donde el profesional de la salud, en este caso un oftalmólogo, hasta que le dan un parte de su estado de salud ocular referente a dicha complicación. Por lo que es de vital importancia y necesidad una mayor agilidad (sin olvidar la eficiencia y precisión de los diagnósticos) en el proceso de detección oportuna de la retinopatía diabética ya que, según datos de la OMS, la diabetes en la población mundial pasó de estar presente en 108 millones de personas, en el año 1980, a la alarmante cantidad de 422 millones de personas en el 2014 (*Diabetes*, n.d.). Al tener una detección temprana de la RD existen muchas más probabilidades de que el paciente no pierda gran parte de la visión o la totalidad de esta, en el peor de los casos, gracias al oportuno tratamiento que se le pueda brindar.

Habiendo expuesto todo lo anterior se puede afirmar que cada vez se hace mucho más necesario la inclusión de la detección asistida por computadora haciendo uso de la inteligencia artificial por medio de la aplicación de técnicas de Deep Learning ya que ha demostrado tener un rendimiento destacado en otras áreas de la detección de anomalías y enfermedades del cuerpo humano como lo son la detección del cáncer o tumores.

Otra ventaja de la aplicación de esta tecnología es que el coste de tiempo y dinero para las tareas de detección se verían reducidas y sin sufrir efectos de variabilidad de resultados por diferencia de conceptos entre expertos. (Orlando et al., 2017)

En este trabajo proponemos una solución a esta problemática por medio del diseño y validación de una estructura de red neuronal convolucional (RNC) aplicada a la detección de imágenes de retina para la respectiva ubicación de estas como imágenes saludables o imágenes con signos de RD, adicionalmente incursionamos en el campo de la clasificación de esta enfermedad de acuerdo con sus niveles de severidad.

Objetivos

Objetivo General

Diseñar e implementar una red neuronal basada en Deep Learning Machine mediante Google Colaboratory para el diagnóstico automatizado de la retinopatía diabética.

Objetivos Específicos

- Realizar un benchmarking de base de datos públicas de Retinopatía Diabética.
- Implementar un clasificador de diagnóstico de retinopatía diabética con Deep Learning Machine.
- Validar los resultados obtenidos con diferentes estructuras de red neuronal basadas en Deep Learning Machine mencionadas en el estado del arte.

Contribuciones

Dentro de las contribuciones hechas mediante la realización del presente proyecto están:

1. Publicación “*Una revisión de los métodos de deep learning aplicados a la detección automatizada de la retinopatía diabética*” el cual consiste en una revisión que abarca un amplio estudio del estado del arte. (Disponible en el siguiente enlace: <https://sextante-ensb.com/index.php/inicio>)
2. Diseño y estructuración de algoritmos de preprocesamiento de imágenes, entrenamiento y evaluación de numerosas redes neuronales convolucionales (Xception, VGG16, VGG19, DenseNet121, DenseNet169, InceptionV3, ResNet50, ResNet101, InceptionResNetV2, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3).
3. Publicación “*CNN model applied to diabetic retinopathy detection*”. Consiste en el enfoque preliminar de las pruebas realizadas para la detección de la retinopatía diabética, el cual se encuentra próximo a ser sometido, por parte de nuestro tutor de tesis, en una revista indexada en Scopus.
4. Validación de la metodología propuesta haciendo uso de distintas bases de datos públicas (APTOS 2019 Blindness Detection, MESSIDOR y MESSIDOR-2).
5. Publicación “*Basic CNN model for diabetic retinopathy detection and classification*”. Se encuentra en estado de revisión por parte de nuestro tutor de tesis, sobre la metodología final desarrollada en esta tesis, que abarca el área de detección y clasificación de la RD comparándola con publicaciones disponibles en el estado del arte. Esta será sometida a una revista categorizada en cuartil Q2.
6. Registro de los algoritmos desarrollados ante la Dirección Nacional de Derechos de autor. (N° de Radicado 1-2021-44690)

Estructura del Documento

La composición de este trabajo será como se describe a continuación. En primera instancia se recopilan diversos trabajos enfocados en el área de la detección y el diagnóstico de la RD, donde los autores exponen los métodos que usaron para abordar dicha problemática, siendo de gran interés las evaluaciones de rendimiento y pruebas que realizaron, las cuales servirán como referencia a manera de comparación del rendimiento del modelo expuesto por nosotros en este documento respecto a dichos trabajos.

Posteriormente se detalla la metodología que se siguió para la elaboración de modelos de CNN enfocados en la detección de la Retinopatía Diabética, siendo que: se define el entorno en el cual se trabajará a lo largo del proyecto, se seleccionará el conjunto de imágenes que se estará usando y las modificaciones hechas en estas, se plantea la forma en cómo se procedió para la estructuración de los modelos, para posteriormente realizar las evaluaciones correspondientes.

Finalmente, se presenta un plan metodológico que mejora en gran medida al explicado en el capítulo anterior, siendo que se resaltan los aspectos que variaron entre una metodología y otra, dentro de los cuales el más significativo es que además de realizar pruebas de detección de RD (2 clases), se incluyen pruebas para evaluar los modelos en la tarea de clasificación del nivel de RD (5 clases).

Estado del Arte

Se ha realizado una extensa labor referente a los trabajos relacionados con sistemas para la detección automatizada de la RD por medio de técnicas de Deep Learning disponibles actualmente en bases de datos, teniendo como criterio de selección el alto impacto de las revistas donde estos hayan sido publicados y el año de la publicación de estos, ya que no se tuvieron en cuenta trabajos que fueron publicados antes del año 2015, de este estudio se logró tener como resultado un artículo de revisión del estado del arte. En él explicamos todo lo referente a los trabajos relacionados a la materia, las contribuciones más destacadas por autores de todo el mundo, los enfoques adoptados por los diferentes autores, las características fisionómicas más descriptivas de la retina en las que se basaron para poder hacer la extracción y entreno por parte de sus modelos-solución propuestos, y las métricas más comunes que usaron para evaluar el rendimiento de estos para así, lograr hacer una comparativa con las otras propuestas planteadas por otros autores. Este artículo se encuentra publicado y disponible en la página principal de la revista SEXTANTE (<https://sextante-ensb.com/index.php/inicio>)

Ahora bien, en esta sección presentamos la revisión del panorama actual de las técnicas y modelos de CNN aplicados a las imágenes oculares retinianas para lograr un diagnóstico automatizado de la retinopatía diabética a partir de la identificación de signos de lesiones ocasionadas por esta enfermedad como lo son los micro aneurismas (MAs), exudados (EXs), hemorragias y anomalías microvasculares intrarretinianas (IRMA, por sus siglas en inglés). Se muestran los diferentes conjuntos de datos de imágenes oculares de acceso público más populares en el ámbito científico. Adicionalmente, se hace una breve explicación de los enfoques utilizados por diferentes investigadores y científicos junto con sus respectivos resultados. Todo

esto con el objetivo de lograr una revisión útil para las investigaciones futuras de las personas que deseen seguir la línea de estudio de la detección de la RD con ayuda de las técnicas de DL.


Aspectos Generales de la Retinopatía Diabética

Además de ser una complicación de la diabetes que afecta los ojos, la retinopatía diabética es una enfermedad progresiva que se diagnostica de acuerdo con algunas anomalías clínicas de difícil detección, debido que es asintomática hasta altas etapas del desarrollo de la enfermedad, y si no se realiza un tratamiento adecuado evoluciona en una patología mayor conocida como edema macular diabético que podría conllevar a la pérdida irreversible de la visión (Giancardo et al., 2012; Rudas & Torres, 2013).

Según Mayo Clinic, (2018) cualquier persona con diabetes tipo 1 o 2 puede padecer este trastorno. Cuanto más tiempo lleve la persona con diabetes y cuanto menos se haya controlado el azúcar en la sangre, mayor es la probabilidad de presentar esta complicación en los ojos. Esta afirmación es soportada por Ishtiaq et al., (2020) cuando explica la forma en la que se desarrolla la retinopatía diabética en el ojo humano, esto es como sigue, la sangre es transportada a las capas del tejido retiniano por micro vasos sanguíneos que requieren un nivel de azúcar en sangre mantenido y un flujo sanguíneo sin obstrucciones. Si una gran cantidad de azúcares, como glucosa o fructosa, se acumulan en la sangre, estos vasos sanguíneos comienzan a descomponerse debido a la distribución inadecuada de oxígeno a las células. Las anomalías estructurales (ver [Figura 2](#)) ocurren como resultado de la disminución de la tasa metabólica que conduce a la RD.

Figura 2.

Imagen de la retina con sus patologías: a) Exudados rodeando un grupo de hemorragias y microaneurismas, b) Exudados duros y blandos.



Fuente: Tomado de (Rudas & Torres, 2013).

Los principales síntomas y patologías de la RD incluyen:

- **Microaneurismas:** Son deformaciones en las paredes de los vasos sanguíneos (Mookiah et al., 2013). Son difíciles de detectar con la oftalmoscopia convencional si no se tiene experiencia, pero aparecen como pequeñas manchas rojas con límites nítidos.
- **Neovascularización:** También llamada isquemia retiniana, ocurre cuando el cierre de los vasos sanguíneos retinianos genera que el suministro de oxígeno que llega a las regiones retinianas sea limitado (Kowluru & Chan, 2008). El crecimiento del endotelio vascular intenta compensar la disminución del suministro de oxígeno, lo que da como resultado la formación de pequeños vasos sanguíneos débiles en la superficie de la retina, lo que conduce a la pérdida de la visión (Badar et al., 2020).

- **Hemorragias:** Son producto del colapso de los microaneurismas y son visualmente apreciables como manchas de sangre sobre la superficie de la retina, de tamaño muy superior a las de los microaneurismas (Rudas & Torres, 2013).
- **Exudados duros:** Los exudados duros son objetos de color amarillo brillante o blanco en la retina. Estos objetos tienen una apariencia cerosa y bordes afilados contra el fondo de los vasos sanguíneos. Los exudados duros se desarrollan debido a la pérdida de sangre de las venas y los exudados tienen forma circular alrededor de los vasos (Salamat et al., 2019).
- **Exudados suaves:** También llamados manchas de algodón, son infartos de la capa de fibras nerviosas; tienen un aspecto más blanquecino (Mittal & Rajam, 2020).


Etapas de la Retinopatía Diabética

La RD se divide en dos etapas principales: no proliferativa y proliferativa, llamada así por la ausencia o presencia de nuevos vasos sanguíneos anormales que emanan de la retina (Fraser et al., 2017) (Ver [Figura 3](#)). Según Mittal & Rajam (Mittal & Rajam, 2020), la primera etapa, la Retinopatía Diabética NO proliferativa (RDNP) se subdivide en las siguientes fases: (1) fase media, (2) fase moderada y (3) fase severa. De acuerdo con Randive et al., (2019), La RDNP crece con el daño de los vasos sanguíneos dentro de la retina, debido que hace que la retina se hinche y se humedezca más debido a la fuga de líquidos en las regiones de la misma.

La segunda etapa, la cual es considerada la etapa avanzada, es la Retinopatía Diabética Proliferativa (RDP). Esta etapa, de acuerdo con la investigación realizada por Asiri et al., (2019), se caracteriza por una proliferación vascular anormal dentro de la retina hacia la cavidad vítrea. Estos frágiles vasos sanguíneos nuevos pueden sangrar en la cavidad vítrea y causar una pérdida visual severa debido a una hemorragia vítrea.

Figura 3.

Imágenes típicas de fondo de retina: (a) Retina normal, (b) Retina en fase media RDNP, (c) Fase moderada RDNP, (d) Fase severa RDNP, (e) Retinopatía diabética proliferativa (RDP).



Fuente: Tomadas del conjunto de imágenes APTOS 2019 Blindness Detection.

Cabe resaltar que la mayoría de los pacientes con retinopatía diabética, en sus etapas tempranas, no notan muchos cambios en la calidad de su visión. Es por eso por lo que una persona con diabetes debe realizarse constantes chequeos médicos para así lograr un oportuno diagnóstico de la enfermedad y comenzar un tratamiento efectivo ya que cuando se presentan síntomas como visión borrosa o deficiencia en la percepción de colores significa que ya la enfermedad ha ido evolucionando considerablemente.

Grados de la Retinopatía Diabética

La clasificación del grado de la RD es una actividad de suma importancia en el proceso de detección y diagnóstico de las enfermedades de la retina (Asiri et al., 2019).

Se cuenta con varios sistemas que se encargan de brindar un estándar para la calificación de los cambios de tipo vascular que se presentan y pueden observarse en las imágenes de fondo de ojo ocasionados por la RD, como la clasificación que fue implementada gracias al Estudio de tratamiento temprano de la retinopatía diabética (ETDRS, por sus siglas en inglés) y el protocolo de clasificación dado por el Ministerio de Salud Neozelandés (Ministry of Health, 2016), en el cual según Asiri et al., (2019) solo se toma un campo por ojo, que se centra en la fovea. El protocolo de clasificación antes mencionado se ve representado y detallado en la [Tabla 1](#).

Tabla 1.

Clasificación de grados de la retinopatía diabética.

Grado	Signos clínicos	Decisión
R0: No RD	No existen anomalías.	Tipo1: Volver a examinar a los 2 años, ajustando los modificadores clínicos.

		Tipo 2: Reevaluación a los 2-3 años, ajustando los modificadores clínicos. La presencia de modificadores clínicos puede requerir una reevaluación más temprana.
R1: Leve	Menos de 5 microaneurismas o puntos de hemorragia	Reevaluación a los 2 años dependiendo de los modificadores clínicos.
R2: Media	Más de 4 microaneurismas o puntos de hemorragia. Exudados > 2 diámetros de disco de la fovea. Algunas manchas y hemorragias más grandes son aceptables. Si hay más de 20MA o hemorragias por campo fotográfico se debe actualizar a R3 Moderado.	Volver a evaluar después de 12 meses.
R3: Moderado	Cualquier característica de R2. Manchas y hemorragias más grandes. Hasta un cuadrante de reborde venoso	Volver a evaluar después de 6 meses.
R4: Severa	Uno o más de: Anomalías microvasculares intrarretinianas definidas (IRMA). Dos cuadrantes o más de cuentas cenosas. Cuatro cuadrantes de manchas o hemorragias más grandes.	Revisión por oftalmólogo en 6 semanas.
R5: Proliferativa	Uno o más de: Neovascularización Hemorragia subhialoidea o vítrea. Desprendimiento de retina por tracción o gliosis de retina.	Remisión urgente a un oftalmólogo; considere revisar dentro de 2 semanas.

Fuente: Adaptado de (Ministry of Health, 2016).

Marco General para los Procesos de Detección de la Retinopatía Diabética

El marco general para la detección, segmentación y clasificación implica los pasos específicos de preprocesamiento, extracción/selección de características, elección de un método de clasificación adecuado y, finalmente, evaluación de los resultados. Los sistemas de clasificación DR se pueden dividir en dos tipos según el procedimiento de aprendizaje: aprendizaje supervisado y no supervisado (Asiri et al., 2019).

Los modelos de aprendizaje supervisado son aquellos en los que se aprenden funciones, relaciones que asocian entradas con salidas, por lo que se ajustan a un conjunto de ejemplos de los que conocemos la relación entre la entrada y la salida deseada. Este hecho incluso llega a


proporcionar una de las clasificaciones más habituales en el tipo de algoritmos que se desarrollan. Así, dependiendo del tipo de salida suele darse una subcategoría que diferencia entre modelos de clasificación, si la salida es un valor categórico (por ejemplo, una enumeración, o un conjunto finito de clases), y modelos de regresión, si la salida es un valor de un espacio continuo, es decir, el sistema se enseña utilizando datos etiquetados para inferir el mapeo funcional (Asiri et al., 2019; Q Li et al., 2015; Sancho Caparrini, 2020).

Por otra parte, los modelos de aprendizaje no supervisado son aquellos en los que no estamos interesados en ajustar pares (entrada, salida), sino en aumentar el conocimiento estructural de los datos disponibles (y posibles datos futuros que provengan del mismo fenómeno)(Sancho Caparrini, 2020).

Es decir, este tipo de modelo hace que la red aprenda por sí misma secuencias o patrones ocultos a partir de las similitudes que encuentra en todo el conjunto de imágenes del que se alimenta (Arunkumar & Karthigaikumar, 2017). Un ejemplo del modelo de una estructura de CNN aplicada a las imágenes de fondo de ojo se observa en la [Figura 4](#).

Figura 4.

Modelo de CNN aplicado a las imágenes de retina.



Fuente: Tomado de (*Diagnóstico de Retinopatía Diabética Aplicando Redes Neuronales Convolucionales* | by EAI / *Data Science Bolivia* | *Medium*, n.d.).

Conjuntos de Imágenes Oculares (Datasets)

En esta sección se mostrará un benchmarking de los conjuntos de datos de mayor uso en las investigaciones y trabajos relacionados a la detección de la RD por medio de técnicas de DL, junto con una breve descripción característica de cada una de las bases de imágenes oculares que se mencionarán.

- **ROC (Retinopathy Online Challenge):** Contiene 100 imágenes digitales a color de fondo de ojo con microaneurismas en todas las imágenes. Estas imágenes se encuentran aleatoriamente distribuidas y se dividen en 50 imágenes para entrenamiento de la red y 50 imágenes para pruebas Niemeijer et al., (2010). El enlace para acceder a esta base de datos de imágenes es:

<http://webeye.ophth.uiowa.edu/ROC/>

- **E-Ophta:** Este conjunto de datos se divide en 2 categorías: Una llamada E-Ophta MA y la otra E-Ophta EX. E-Ophta MA posee 148 imágenes con microaneurismas y pequeñas hemorragias y 233 imágenes sin lesiones, en cambio E-Ophta EX posee un conjunto de 47 imágenes de fondo de ojo con una segmentación de exudados y 35 imágenes sin ningún tipo de lesión y que se encuentran etiquetadas como imágenes normales E. Decencière et al., (2013). El enlace para acceder a este dataset es: <http://www.adcis.net/en/third-party/e-ophta/>
- **Kaggle DR Dataset:** Esta base de datos es proporcionada por EyePACS, (n.d.), para colaborar en la investigación y desarrollo de trabajos relacionados a la detección y diagnóstico de la RD. En total posee 88,702 imágenes, de las cuales 35,126 son para tareas de entrenamiento y 53,576 son para tareas de pruebas. El enlace para acceder a este dataset es: <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>
- **DIARETDB0:** Consiste en 130 imágenes de fondo de ojo, de las cuales 110 presentan signos de RD y 20 imágenes son de ojos sanos. En esta base de datos las imágenes que pertenecen al grupo de RD contienen la etiqueta de los signos que presentan, es decir, exudados, microaneurismas, hemorragias y neovascularización (Kauppi et al., n.d.). El enlace para acceder a ella es: <https://www.it.lut.fi/project/imageret/diaretdb0/>
- **DIARETDB1:** La base de datos consta de 89 imágenes de fondo de ojo en color de las cuales 84 contienen al menos signos no proliferativos leves (microaneurismas) de la retinopatía diabética, y 5 se consideran normales que no contienen ningún signo de la retinopatía diabética según todos los expertos que participaron en la evaluación. Las imágenes se

capturaron utilizando una cámara de fondo de ojo digital con campo de visión de 50 grados con diferentes configuraciones de imagen. Los datos corresponden a una situación práctica buena (no necesariamente típica), donde las imágenes son comparables y pueden usarse para evaluar el desempeño general de los métodos de diagnóstico (Kauppi et al., n.d.). El enlace para ir a esta base de datos es: <https://www.it.lut.fi/project/imageret/diaretdb1/>

- **Messidor:** Consta de 1200 imágenes numéricas de color de fondo de ojo. Las imágenes se capturaron utilizando 8 bits por plano de color a 1440*960, 2240*1488 o 2304*1536 píxeles. Posee 800 imágenes con dilatación pupilar (una gota de tropicamida al 0,5%) y 400 sin dilatación. Todo el conjunto de imágenes se encuentra empaquetada en 3 juegos. Cada conjunto está dividido en 4 subconjuntos comprimidos que contienen 100 imágenes en formato TIFF y un archivo Excel con diagnósticos médicos para cada imagen (Etienne Decencière et al., 2014). El enlace de esta base de datos es el siguiente:

<http://www.adcis.net/en/third-party/messidor/>

- **DRIVE:** La base de datos DRIVE se ha establecido para permitir estudios comparativos sobre la segmentación de los vasos sanguíneos en las imágenes de la retina. Consta de 40 fotografías, de las cuales 33 no presentan ningún tipo de RD y 7 muestran signos de RD temprana leve. La resolución de las imágenes es de 768*584 píxeles. En este conjunto de datos 20 imágenes son de entrenamiento y la misma cantidad para pruebas (Aggarwal & Khare, 2015). El enlace para acceder a ella es: <https://drive.grand-challenge.org/DRIVE/>

- **STARE:** Consta de 400 imágenes en total. Las imágenes poseen anotaciones de expertos según las características visibles de cada imagen, las cuales se encuentran tabuladas en archivos de texto. El enlace para acceder a esta base de datos es el siguiente:

<https://cecas.clemson.edu/~ahoover/stare/>

- **APTOS 2019:** Consta de 10 GB de datos en 5.590 imágenes RGB del fondo de ojo. Los propietarios de los datos los dividieron en dos partes, en concreto, el conjunto de datos de entrenamiento consta de 3.662 imágenes con etiquetas de destino y 1.928 del conjunto de datos de prueba sin etiquetas. Como cualquier conjunto de datos del mundo real, hay ruido tanto en las imágenes como en las etiquetas. Las imágenes pueden contener artefactos, estar desenfocadas, subexpuestas o sobreexpuestas. Las imágenes se recogieron en múltiples clínicas utilizando diversas cámaras durante un largo periodo de tiempo, lo que afecta a una mayor variación (Pak et al., 2020). El enlace para acceder a este conjunto de imágenes es:

<https://www.kaggle.com/c/aptos2019-blindness-detection/overview>

Métricas de Rendimiento

A continuación, se mostrarán las métricas de rendimiento más utilizadas por los investigadores para poder establecer una comparativa entre los resultados obtenidos por los trabajos académicos, realizados por otras personas o por ellos mismos en el diagnóstico de las enfermedades oculares, de los que disponen en su estado del arte y los resultados obtenidos en su actual investigación. Para hacer esta comparativa se utilizan lo que conocemos como métricas estadísticas, estas métricas son las que van a mostrar que tan en acuerdo o qué tan en desacuerdo

están el experto y el método propuesto para calificar una enfermedad ocular (Farsiu et al., 2014); (Perdomo & González, 2019). Estas métricas de rendimiento se muestran en la [Tabla 2](#).

Tabla 2. Métricas de rendimiento más comunes en Deep Learning.

Medida	Formula	Descripción
Sensitividad (Se o recall)	$\frac{TP}{TP + FN}$	Relación entre los verdaderos positivos clasificados y los verdaderos positivos reales en la verdad básica. También conocido como tasa de verdaderos positivos (TPR).
Especificidad (Sp)	$\frac{TN}{(TN + FP)}$	Relación entre los verdaderos negativos clasificados y los verdaderos negativos reales en la verdad básica. (1-SP) también se conoce como tasa de falsos positivos (FPR).
Exactitud (Acc)	$\frac{TP + TN}{TP + TN + FP + FN}$	La precisión mide la proporción de píxeles clasificados correctamente (tanto de los vasos como de los no vasos) con respecto al número total de píxeles en el campo de visión de la imagen (FOV).
Precisión (Pr)	$\frac{TP}{(TP + FP)}$	El porcentaje de casos positivos detectados.
Área bajo la curva (AUC)	$\frac{Se + Sp}{2}$	Área cubierta por la curva ROC cuando se logra la optimización.
Puntuación – F	$2 * \frac{Se + Pr}{(Se + Pr)}$	F-score es el promedio ponderado de precisión y recuerdo. Tiene en cuenta tanto los falsos positivos como los falsos negativos.
Coefficiente Kappa	$\frac{p_o - p_e}{1 - p_e}$	El coeficiente Kappa refleja la concordancia interobservador, puede tomar valores entre -1 y +1. Mientras más cercano a +1, mayor es el grado de concordancia interobservador, por el contrario, mientras más cercano a -1, mayor es el grado de discordancia interobservador. (Cerde & Villarroel Del, 2008)

Fuente: Tomado y adaptado de (Badar et al., 2020; Mittal & Rajam, 2020; Perdomo & González, 2019).

Donde:

TP = Positivos verdaderos (número de píxeles del vaso correctamente clasificados).

TN = Negativo verdadero (número de píxeles de fondo correctamente clasificados)

FP = Falsos positivos (número de píxeles de fondo clasificados incorrectamente).

FN = Falsos negativos (número de píxeles del vaso incorrectamente clasificados).

p_o = Probabilidad de acuerdo o clasificación correcta entre los clasificadores.

p_e = Probabilidad de acuerdo de azar entre los clasificadores.

Extracción de Características y Métodos de Deep Learning como Herramienta para el Diagnóstico Automatizado de la Retinopatía Diabética.

De acuerdo con la investigación ejecutada por Randive et al., (2019), para clasificar la RD, cada imagen del fondo digital está representada por un vector de características visuales llamado Firma. Se encuentra que los microaneurismas, las hemorragias, los exudados y las anomalías microvasculares intraretinianas aparecen con varios vectores significativos de características visuales o firmas como son el tamaño, la forma, el color, la intensidad, la textura, la densidad de vasos sanguíneos, el contraste, entre otros. Es por esto por lo que muchos investigadores centran el desarrollo de su estudio en la extracción de dichas características, ya que así se puede determinar si existe algún tipo de anomalía teniendo como referencia una imagen de fondo de ojo en estado sano.

Es el caso de Arunkumar & Karthigaikumar, (2017), el cual presenta un trabajo para el diagnóstico de enfermedades oculares a través de la extracción de características de DL y un clasificador SVM (Support Vector Machine) de varias clases (Chetoui & Akhloufi, 2020) propuso un método con el cual gracias a la extracción de características logró demostrar que el modelo era capaz de identificar de manera eficiente diferentes signos de RD. La red propuesta logró unas métricas de rendimiento considerablemente altas, con un AUC de 0,986 usando la base de datos EyePACS. Y para MESSIDOR, MESSIDOR-2, DIARETDB0, DIARETDB1, STARE, IDRID, E-optha y UoA-DR, logró un AUC de 0.963, 0.979, 0.986, 0.988, 0.964, 0.957, 0.984 y 0.990, respectivamente.

Por otra parte, Wu et al., (2016) propuso un método que utiliza una red neuronal convolucional profunda (CNN) para poder conocer las características de apariencia del objetivo. Los resultados cualitativos y cuantitativos sobre los datos del fondo de retina demostraron que los autores lograron una precisión comparable con métodos más avanzados.

Zhao et al., (2018) presenta un algoritmo de segmentación y localización del disco óptico de forma automática basado en una red tipo Faster R-CNN y un conjunto de niveles con restricciones de forma. El algoritmo fue entrenado con 4000 imágenes tomadas de Kaggle y probadas en la base de datos MESSIDOR, logrando una puntuación promedio de coincidencia del 85,4%.

Maninis et al., (2016) expone en su investigación lo que se conoce como Comprensión profunda de la imagen retiniana (DRIU, por sus siglas en inglés), el cual es un marco unificado de análisis de imágenes retinianas que proporciona segmentación de los vasos retinianos y del disco óptico. Hace uso de CNN, la cual en su arquitectura se encuentran dos conjuntos de capas especializadas para resolver la segmentación de los vasos retinianos y del disco óptico, así como el trabajo de Qiaoliang Li et al., (2016), en donde presentan un método para la segmentación de dicha estructura ocular pero haciendo uso de un método supervisado.

He et al., (2016a) presenta una metodología en la que reformula explícitamente las capas de su red como funciones residuales de aprendizaje con referencia a las entradas de las capas, en lugar de aprender funciones no referenciadas.

Gondal et al., (2018) en su publicación muestra que en las imágenes de las retinas se detectan diferentes áreas de lesiones fundamentales para el diagnóstico oportuno de la RD a nivel de imagen con una alta precisión, comparable e incluso superando a los métodos supervisados. A nivel de las lesiones, logró pocos falsos positivos con alta sensibilidad, sin embargo, la red está únicamente entrenada en etiquetas a nivel de imagen que no incluyen información sobre las lesiones existentes. Clasificando entre imágenes enfermas y sanas, Gondal et al. Logró un AUC de 0,954 usando la base de datos DiaretDB1.

Escorcia-Gutierrez et al., (2016) en su trabajo manifiesta que logró la segmentación de la principal estructura anatómica de la retina, la cual es el disco óptico, haciendo uso del algoritmo Convexity Shape Prior. Además, como aporte complementario explica la forma en que se alcanzó la extracción de los vasos sanguíneos por medio de filtros como el filtro de onda media, mediana, Gaussiana y Gabor.

Zilly et al., (2015) propone un método basado en una CNN para la segmentación del disco y la copa óptica. Entrena un clasificador de regresión logística tipo softmax posterior al proceso de los filtros, los cuales aprenden a lo largo de varias capas y la salida de las capas anteriores alimentan a las capas siguientes.

Q Li et al., (2015) desarrolla una investigación enfocada a la aplicación de un método supervisado para la segmentación de los vasos de la retina. Esto lo hace con una red neuronal tipo CNN y usaron el conjunto de datos de DRIVE. Pero más tarde, (Qiaoliang Li et al., 2016), propone una mejora al enfoque de segmentación de los vasos presentado anteriormente y

presenta una red neural amplia y profunda con gran capacidad para realizar el modelado de una transformación. Esta red, en lugar de analizar solo el píxel central puede analizar y dar salida a un mapa de etiquetas de todos los píxeles para una imagen. Como característica adicional de este modelo presentado por (Qiaoliang Li et al., 2016), se puede resaltar el hecho que no necesita ningún paso de preprocesamiento de la imagen. En adición a esto, (Mo & Zhang, 2017), sigue la misma línea de segmentación vasos y presenta una red totalmente convolucional supervisada en profundidad aprovechando las características jerárquicas multinivel de las redes profundas. Usaron las bases de datos de DRIVE, STARE Y CHASE_DB1, logrando resultados exitosos.

Lim et al., (2016) describe una solución integral, para la segmentación del disco y la copa ópticos, basada en la aplicación de CNN. En esta solución hace uso de mapas de probabilidades los cuales son refinados con conocimientos previos de las estructuras retinianas, haciendo énfasis en que logrando la proporción entre la copa y el disco óptico puede lograr una detección eficaz de enfermedades como el glaucoma y la RD. Este estudio lo hizo con ayuda de dos bases de datos muy populares, una de ellas MESSIDOR.

Abràmoff et al., (2016) hicieron una comparativa del rendimiento de un algoritmo mejorado de DL para la detección automatizada de la RD con el rendimiento publicado con anterioridad de ese mismo algoritmo. Para la clasificación usaron el estándar de referencia de consenso reportado previamente de RD referible, definido como Clasificación Clínica Internacional de Retinopatía diabética moderada, no proliferativa severa (NPDR, por sus siglas en inglés), RD proliferativa y/o edema macular (ME, por sus siglas en inglés). Los resultados

fueron los siguiente: 96,8% de sensibilidad, la especificidad fue del 87,0%, con 6/784 falsos negativos, lo cual significó un valor predictivo negativo del 99,0% y el AUC fue de 0,980.

Saranya Rubini et al., (2019) propone un modelo de aprendizaje profundo automatizado para la detección de la RD basada en CNN la cual es capaz de analizar las imágenes de la retina y clasificarlas como sanas o defectuosas según los síntomas de la RD. El modelo posee cinco capas de convolución y cinco agrupadas seguidas de una capa de abandono y tres capas completamente conectadas. Este modelo no necesita preprocesamiento y aprende características discriminatorias de alto nivel de los síntomas de DR a partir de las intensidades de píxeles para clasificar la imagen de la retina como sana o defectuosa. Se usaron los conjuntos de datos MESSIDOR y ROC, obteniéndose una precisión de detección del 97%.

Chetoui & Akhloufi, (2020) desarrollaron un algoritmo de DL capaz de detectar signos de RD en imágenes del fondo de ojo de la retina. Utilizan los conjuntos de datos EyePACS, MESSIDOR, MESSIDOR-2, DIARETDB0, DIARETDB1, STARE, IDRID, E-ophtha y UoA-DR y más de 90,000 imágenes para evaluar la eficiencia del algoritmo. Además, implementaron un algoritmo de explicabilidad basado en el mapeo de activación de clases ponderado por gradiente para mostrar visualmente los signos seleccionados por el modelo para clasificar las imágenes de la retina como positivos para RD. Los resultados obtenidos fueron: área bajo la curva (AUC) de 0,986, sensibilidad de 0,958 y especificidad de 0,971 para EyePACS. Para MESSIDOR, MESSIDOR-2, DIARETDB0, DIARETDB1, STARE, IDRID, E-ophtha y UoA-DR, el AUC es 0.963, 0.979, 0.986, 0.988, 0.964, 0.957, 0.984 y 0.990, respectivamente.

Gangwar & Ravi, (2021) exponen un trabajo en el que proponen un híbrido de DL para la detección automática de la RD. Este híbrido se compone de un bloque personalizado de capas CNN sobre el modelo de aprendizaje por transferencia de Inception-ResNet-v2 previamente entrenado. Usaron el conjunto de datos MESSIDOR y APTOS 2019. Lograron una precisión de prueba del 72,33% y el 82,18% en el conjunto de datos MESSIDOR y APTOS, respectivamente.

Guisela & Pozo, (2019) sugieren analizar e implementar modelos de redes neuronales artificiales supervisadas para la detección de estructuras vasculares retinianas de fondo de ojo. Aplicaron una red convolucional basada en la arquitectura U-Net, con ventanas de imagen de 16x16 píxeles. La red convolucional estaba compuesta por cuatro capas convolucionales y tres capas deconvolucionales. Obtuvieron unos resultados de sensibilidad del 74,20%, una especificidad del 90,70% y una exactitud del 88,22%.

Merino Hernandez et al., (2019) desarrollaron un algoritmo innovador basado en métodos avanzados de clasificación (Deep Learning y Support Vector Machine) que identifica automáticamente las imágenes patológicas de forma eficaz y segura. El software discrimina automáticamente retinografías normales y patológicas. Los resultados obtenidos fueron sensibilidad de 94% y una especificidad del 96%.

Auccahuasi et al., (2020) presentan una metodología para poder reconocer los exudados duros que es la primera manifestación de la retinopatía diabética, describiendo una nueva alternativa para el reconocimiento automático de exudados duros en las imágenes de la retina. Por medio de una CNN se trabaja con un conjunto de datos compuesto por 906 imágenes de

exudados duros y 1068 imágenes que no corresponden a exudados duros, que se entrena con un grupo de 400 imágenes con una prevalencia de 0,5 con respecto a la presencia de exudados duros, después de esto se hacen dos comprobaciones al clasificador utilizando grupos de imágenes similares, como el grupo de pruebas y validación, obteniendo valores de sensibilidad de 0,92% en ambos casos y valores de especificidad de 0,92% y 0,93% para los grupos de imágenes de prueba y validación, respectivamente. Se realizaron mediciones adicionales para calcular el Valor Predictivo Positivo y el Valor Predictivo Negativo, obteniéndose valores de 0,9207% para el grupo de imágenes de prueba y 0,93% para el grupo de imágenes de validación, en el caso del Valor Predictivo Negativo se obtuvieron valores de 0,9292% para el grupo de imágenes de prueba y 0,93% para el grupo de imágenes de validación.

Moreira et al., (2020) formula el desarrollo de CNNs para detectar la RD, y el impacto de la resolución y la red de imágenes en la precisión de la predicción. Obtiene unos resultados de un área de 0,93 bajo la curva característica operativa del receptor al aumentar la resolución de la arquitectura Inception-V3.

Samper et al., (2020) presenta una metodología para la detección y segmentación del disco óptico y los vasos sanguíneos en imágenes de fondo de ojo de pacientes con RD. Hace uso del conjunto de datos DRIVE y logra una precisión (Acc) de 95% y una especificidad (Sp) de 98% para la segmentación de los vasos sanguíneos y una precisión de 94,6% y 97.8% en especificidad para la segmentación del disco óptico.

Bodapati et al., (2021a) propone una arquitectura de red neuronal profunda compuesta con un mecanismo de atención cerrada para el diagnóstico automatizado de la retinopatía diabética. Usaron el conjunto de datos de APTOS 2019 Blindness Detection (*APTOS 2019 Blindness Detection / Kaggle*, n.d.-a) obteniendo una exactitud de 82.54% y 79 punto en la puntuación Kappa para tareas de clasificación según el nivel de RD.

Adriman et al., (2021) presenta un trabajo de clasificación binaria para la detección de la RD usando modelos de Aprendizaje Profundo por medio de la técnica de características de textura de la imagen. Para la extracción de las características de textura usaron el método de patrones binarios locales (LBP, por sus siglas en inglés), este fue aplicado a cada imagen en la etapa de preprocesamiento, finalmente entre las redes que probaron para la clasificación binaria de la retinopatía diabética se encuentran DenseNet (Huang et al., 2017) y ResNet (He et al., 2016b). Alcanzando una exactitud de 96.35% para el caso de DenseNet y 84.05% para el caso de ResNet.

Por otro lado en el trabajo desarrollado por Lam et al., (2018) demostraron el uso de redes neuronales convolucionales en imágenes de fondo de ojo para el de reconocimiento de la estadificación de la retinopatía diabética. Además, exploraron los modelos de clasificación multinomial y demostraron que los errores se producen principalmente en la clasificación errónea de la enfermedad leve como normal debido a la incapacidad de las RNC para detectar las características sutiles de la enfermedad. Finalmente exponen que el preprocesamiento con ecualización adaptativa del histograma limitada por el contraste y la garantía de la fidelidad del conjunto de datos mediante la verificación por parte de expertos de las etiquetas de clase mejora

el reconocimiento de las características sutiles. Ellos hicieron uso del conjunto de datos de MESSIDOR y aplicaron de la técnica de aprendizaje por transferencia alcanzando una exactitud en sus conjuntos de prueba de 74.5% y 57.2% para 2 y 4 niveles, respectivamente.

Mansour, (2018) aplica la red neuronal profunda AlexNet, que funciona sobre la base de una RNC para permitir una solución óptima de CAD de RD. En sus resultados con los conjuntos de datos de fondo de ojo estándar de Kaggle demuestra que la detección de la RD basado en AlexNet muestra un mejor rendimiento con la selección de características, donde exhibe una exactitud de clasificación para 2 clases (detección) de RD del 97.93%.

Pak et al., (2020) propone una comparación entre dos arquitecturas convencionales ampliamente utilizadas (DenseNet, ResNet) y también propone una red optimizada como lo es EfficientNetB4. Los métodos propuestos clasifican la imagen de la retina en uno de los 5 niveles posibles, hace uso del conjunto de imágenes de APTOS 2019 Blindness Detection y logra valores kappa de 0.69 para el caso de DenseNet121; 0.708 para ResNet50; 0.734 para ResNet101 y 0.79 para EfficientNetB4.

Vives-Boix & Ruiz-Fernández, (2021) propone un enfoque bioinspirado en la meta plasticidad sináptica en redes neuronales convolucionales. Se sabe que este fenómeno biológico interfiere directamente tanto en el aprendizaje como en la memoria al reforzar situaciones menos comunes durante el proceso de aprendizaje. La meta plasticidad sináptica se ha incluido en la etapa de retro propagación de una operación de convolución para cada capa convolucional. Evalúa su método con el conjunto de APTOS 2019 Blindness Detection y sus mejores resultados

los obtiene con la red de Inception-V3 con una exactitud de 95.56%, puntuación F1 de 94.24%, precisión de 98.9% y sensibilidad del 90%.

Xu et al., (n.d.) hace uso de la metodología de redes neuronales convolucionales profundas para la detección automática de la retinopatía diabética utilizando una imagen de fondo de ojo en color. Aplican la técnica de aumento de datos (*data augmentation*) utilizando cinco tipos de transformaciones diferentes, que incluyen rotación, volteo, corte, cambio de escala y traslación. Desarrollan su propio clasificador basado en características obteniendo así, una exactitud del 94.5%.

Por último, en la investigación adelantada por Khalifa et al., (2019) este validó modelos de aprendizaje profundo para la detección médica de RD. Para cada uno de los modelos hizo uso de la técnica de aprendizaje por transferencia, adicionalmente realizó su estudio haciendo uso del conjunto de imágenes de APTOS 2019 Blindness Detection y los resultados de exactitud para las redes de VGG16, VGG19 y ResNet fueron 97.8%, 97.4% y 96.3%, respectivamente.

Los trabajos mostrados con anterioridad son muestra del extenso desarrollo e investigación que presenta en la actualidad la ciencia de la inteligencia artificial (IA) y su rama conocida como aprendizaje profundo (DL, por sus siglas en inglés) aplicada a la detección automatizada de la RD. Se observa que muchos son los investigadores que han logrado exitosos resultados en el proceso de segmentación de las estructuras oculares, detección de anomalías y patologías presentes en las imágenes de fondo de ojo e incluso han logrado, haciendo uso de técnicas de Deep Learning, establecer algoritmos, los cuales de forma automática y con unas

altas métricas de rendimiento, logran tanto detectar la presencia de signos de RD, como establecer el grado de dicha enfermedad que puede presentar un paciente, posterior a que estos hayan sido entrenados con diferentes conjuntos de datos de imágenes oculares.

Enfoque Preliminar del Proyecto

(Detección de la Retinopatía Diabética)

En esta sección se describe la manera en la que se estructuró el primer modelo elaborado, la adecuación al entorno de trabajo, la selección del conjunto de imágenes a utilizar, las condiciones bajo las que se creó y entrenó la red, y los resultados alcanzados, los cuales, en ese momento estaban enfocados únicamente en la detección de la Retinopatía Diabética.

Entorno de Trabajo

Todos los procedimientos descritos a continuación se llevaron a cabo en el entorno de Google Colaboratory (*Te Damos La Bienvenida a Colaboratory - Colaboratory*, n.d.), el cual nos proporciona un entorno de ejecución con GPU propio de Google, reduciendo considerablemente los recursos necesarios para tareas que requieran una alta capacidad de procesamiento. Este entorno nos asigna aleatoriamente alguno de las tarjetas gráficas disponibles, entre las cuales están la K80, T4, P4 y P100 de NVIDIA, con hasta 12.72 GB de RAM. Si bien permite desempeñar las labores de manera más eficiente, hay que tener en cuenta que existen límites en algunos aspectos, como la capacidad de procesamiento, almacenamiento y la duración de las sesiones activas, esto con el fin de garantizar la mayor disponibilidad de estos recursos al público posible.

Descripción y Procesamiento del Conjunto de Imágenes


Haciendo una revisión de varios de los conjuntos de imágenes dirigidos al estudio de la Retinopatía Diabética, decidimos hacer uso de uno que se encuentra disponible en la plataforma

de Kaggle, correspondiente a la competencia de APTOS 2019 Blindness Detection (*APTOS 2019 Blindness Detection / Kaggle*, n.d.-b), ya que la calidad de las imágenes es aceptable y el tamaño del conjunto de imágenes es lo suficientemente grande para realizar entrenamientos satisfactoriamente sin llegar a saturar la memoria disponible del entorno de trabajo. Esta competencia consta de una carpeta de 3662 imágenes de fondo de ojo destinadas a usarse para el proceso de entrenamiento de la red, así como de otra carpeta con 1928 imágenes para poder realizar pruebas. Sin embargo, al ser una competencia en Kaggle que consiste en hacer predicciones sobre el grupo de prueba, estas últimas imágenes no se encuentran etiquetadas, por lo cual no existe forma de hacer comparaciones haciendo uso de estas, trabajando así, únicamente con las primeras 3662 imágenes mencionadas.

Por otra parte, las imágenes originales presentan dimensiones muy variadas, lo cual es un obstáculo para el aprendizaje de la red, por lo cual, es necesario someterlas a un preprocesamiento para garantizar un óptimo entrenamiento en la red. Para esta tarea nos basamos en las técnicas estudiadas por (*APTOS: Eye Preprocessing in Diabetic Retinopathy | Kaggle*, n.d.), el cual brinda una forma de recortar lo máximo posible las zonas oscuras de las imágenes, para luego reajustar su tamaño al que se desee (para estas pruebas escogimos trabajar con tamaños de 224x224 píxeles); además, mediante el uso de máscaras y la eliminación de ruido gaussiano, se obtienen imágenes procesadas con vasos sanguíneos y lesiones más resaltadas. La [Figura 5](#) permite apreciar el cambio que presentan dichas imágenes.

Figura 5.

Imágenes antes y después de pasar por el algoritmo de procesamiento: a) Imágenes originales, b) Imágenes procesadas.




Fuente: Conjunto de imágenes “APTOS 2019 Blindness Detection” [20] y los autores.

La competencia de APTOS cuenta con un archivo .csv donde se encuentran etiquetadas las imágenes a usar en 5 clases, teniendo los niveles 0, 1, 2, 3 y 4, correspondientes a las clases “No RD”, “Medio”, “Moderado”, “Severo” y “RD Proliferativa” respectivamente. El conjunto de imágenes presenta un gran desbalance en cuanto a al número de muestras pertenecientes a cada clase, estando distribuidas como lo muestra la Figura 6a. Este es un aspecto muy importante al momento de dividir el conjunto de imágenes en los grupos destinados a usarse para el entrenamiento de la red, su validación y su evaluación, siendo ideal que estos tres subconjuntos,

distribuidos como lo muestra la [Figura 6b](#), conserven las mismas proporciones en cuanto a cantidad de datos de la [Figura 6a](#).

Figura 6.

Distribución del conjunto de imágenes: a) Porcentaje de imágenes por nivel de RD, b) Porcentaje de imágenes para entrenamiento, validación y pruebas



Fuente: Los autores.

Metodología Propuesta

Para la construcción de la CNN recurrimos a diversas técnicas descritas por Torres, (n.d.), como lo son Transfer Learning, Feature Extraction y Fine Tuning, las cuales facilitan el desarrollo de nuevas redes en base a modelos creados con anterioridad y reducir así los recursos computacionales requeridos para entrenar la CNN.

- **Transfer Learning (Aprendizaje por Transferencia):** Es una técnica que nos permite hacer uso de un modelo abierto al público y que ha sido entrenado y evaluado anteriormente con un gran conjunto de datos. Para ello recurrimos a Keras *Getting Started*, (n.d.), una librería de

redes neuronales de código abierto que cuenta con una serie de modelos útiles para la realización de prácticas de Deep Learning, disponibles en *Keras Applications*, (n.d.). Esta librería hace parte de la API de TensorFlow, la cual es compatible con el entorno de desarrollo de Google Colaboratory.

- Para esto, se usaron los modelos ResNet50, Xception, VGG16, DenseNet121 y EfficientNetB0, los cuales cuentan con sus propios pesos en cada una de sus capas, predefinidos en base a un conjunto de imágenes utilizado por Keras, conocido como “Imagenet”.

- **Feature Extraction (Extracción de características):** Consiste en hacer uso de los patrones que la red pre entrenada utiliza para el reconocimiento de las características de una imagen en base a conceptos genéricos, como formas, contornos, colores, etc. Para tal fin se implementa una técnica conocida como “congelamiento de capas”, mediante la cual se especifica que se mantendrán los pesos en las capas que conforman la red pre entrenada, conservando el conocimiento que han adquirido para la interpretación de la información en las imágenes. Además de lo anterior, se hace necesario eliminar un conjunto de capas pertenecientes a los últimos bloques de capas que conforman la red en cuestión, conocido como *clasificador final*. Dichas capas están destinadas a la clasificación de las distintas clases con las cuales se entrenó la red originalmente, por lo cual se requiere omitirlas (indicando *include_top=False* al importar la red) y definir un nuevo clasificador específico para la tarea en cuestión. Para nuestro tema de interés, que es el reconocimiento de la presencia de RD, basados en (Monterreal, n.d.) se tiene un clasificador sencillo, conformado por 3 capas: *GlobalAveragePooling* de 2 dimensiones, una capa *Dropout* que permite indicar el porcentaje total deseado de interconexiones entre las

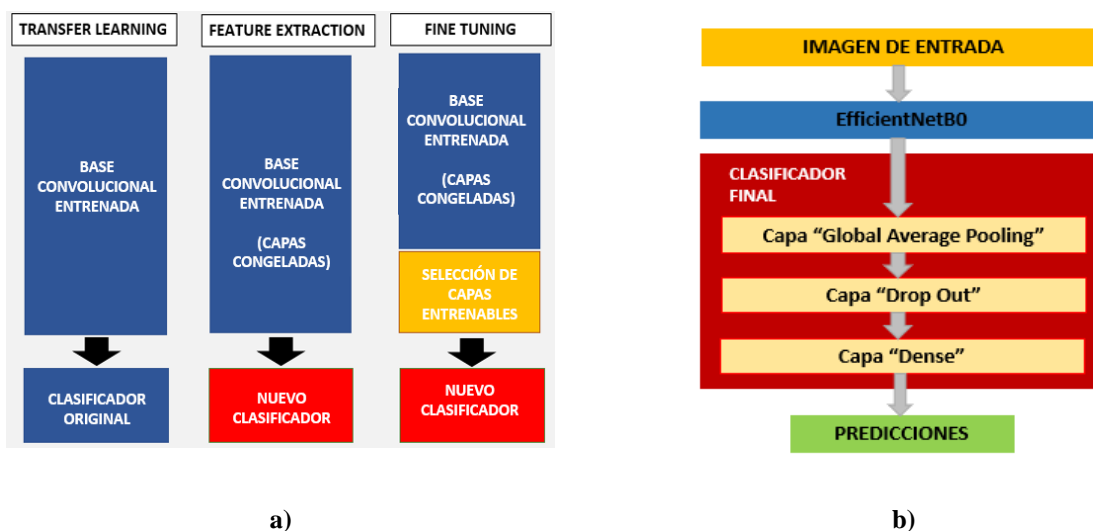
neuronas de la red con el fin de reducir efectos de sobreajuste, y una capa *Dense* con activación *sigmoid*, la cual ayuda a determinar el número de clases que deberá distinguir la red dependiendo al número de neuronas que posea (En este caso serían 2 Neuronas)..

- **Fine Tuning (Ajuste fino):** Consiste en habilitar algunas de las capas que preceden al clasificador final para que puedan entrenarse y, durante el proceso, actualizar sus pesos a unos valores que permitan distinguir características más abstractas, propias de las imágenes que se le estarán mostrando.

Así, la [Figura 7a](#) representa un diagrama que ayuda a interpretar las modificaciones en los 5 modelos de redes evaluados en este trabajo, tomando como punto de partida las 5 redes pre entrenadas: ResNet50, Xception, VGG16, DenseNet121 y EfficientNetB0. La [Figura 7b](#) hace uso de la red EfficientNetB0 para ejemplificar la estructura de los 5 modelos a entrenar.

Figura 7.

Diagramas de bloque con la estructura de la red: a) Diagrama de la estructura simplificada de la CNN, b) Diagrama de construcción de la red a entrenar usando EfficientNetB0 para el Aprendizaje por transferencia.

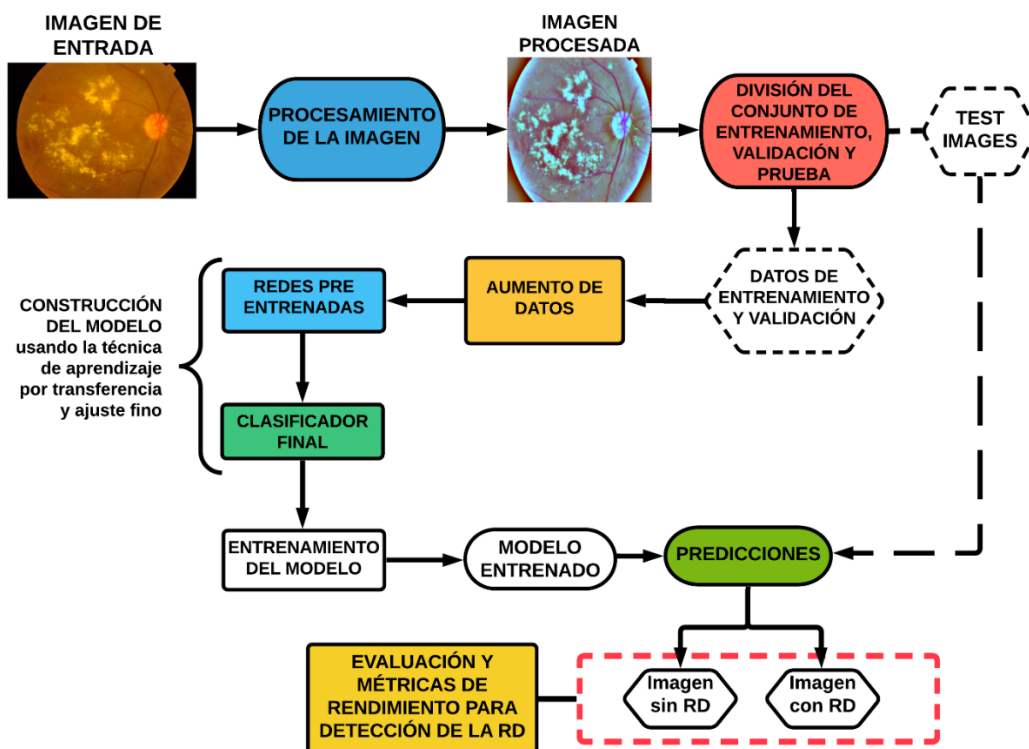


Fuente: Los autores.

- **Data Augmentation:** Otra técnica usada fue el Data augmentation, que resulta muy útil para cuando se cuenta con pocas muestras. Con esta se logra “aumentar” el número de imágenes que el modelo llega a ver durante el entrenamiento, permitiéndole observar la misma imagen varias veces, pero con alteraciones que ayudan a que la red la analice desde diferentes perspectivas. En este caso, al aplicar cierto grado de zoom, rotaciones y voltear la imagen de manera vertical y horizontal, se logra que la red no se “acostumbre” a ver imágenes de fondo de ojo en un solo sentido y que pueda reaccionar adecuadamente al presentarle imágenes variadas. Así, la [Figura 8](#) sintetiza la metodología para la construcción de las redes.

Figura 8.

Ilustración del modelo general para la detección de la RD usando técnicas de Aprendizaje Profundo.



Fuente: Los autores.

Por último, es necesario indicar las condiciones y parámetros bajo los que se realizaron los entrenamientos de las redes. Estas serían:

- Optimizador tipo Adam con un Learning Rate fijo de $1e-4$.
- El tamaño de lote (Batch Size) fue de 32.
- Se estipularon 30 epochs para cada entrenamiento.
- Función de “loss” establecida como `binary_crossentropy`.
- Para “metrics” se indicó únicamente “accuracy”.

Resultados

Una vez estructurada la red, configurados los parámetros y definidas las métricas a usar en la evaluación de esta, se realizaron una serie de entrenamientos con diferentes redes pre entrenadas como base. La [Tabla 3](#) ofrece un resumen de las medidas que ayudan a determinar el rendimiento de las redes para la tarea de la detección de la RD.

Estos resultados se obtienen a partir de una serie de matrices de confusión, visualizadas en las [Figuras 9, 10, 11, 12 y 13](#), las cuales presentan las predicciones hechas por las redes ResNet50, Xception, VGG16, DenseNet121 y EfficientNetB0 respectivamente, e indican la forma en que se encuentran distribuidos los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos.


Tabla 3.

Resultados para la detección de la RD con el conjunto de imágenes de APTOS en nuestro enfoque preliminar.

Red Preentrenada	Exactitud (%)	Precisión (%)	Sens. (%)	Especi. (%)	Puntaje F1 (%)	Coefficiente Kappa (%)	AUC (%)
ResNet50	95.42	97.73	93.14	97.77	95.38	90.85	95.46
Xception	94.14	93.29	95.31	92.94	94.29	88.27	94.12
VGG16	95.79	97.74	93.86	97.78	95.76	91.58	95.82
DenseNet121	95.97	96.7	95.31	96.65	96.00	91.94	95.98
EfficientNetB0	96.89	98.15	95.67	98.14	96.89	93.77	96.9

Figura 9.

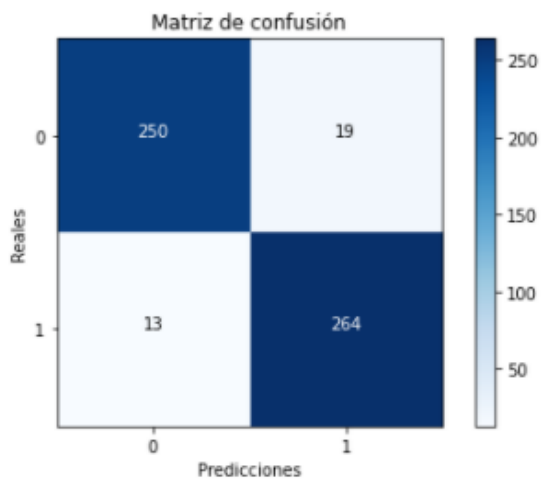
Matriz de confusión obtenida con ResNet50 en el proceso de detección de la RD con conjunto de prueba.



Fuente: Los autores.

Figura 10.


Matriz de confusión obtenida con Xception en el proceso de detección de la RD con conjunto de prueba.



Fuente: Los autores.

Figura 11.


Matriz de confusión obtenida con VGG16 en el proceso de detección de la RD con conjunto de prueba.



Fuente: Los autores.

Figura 12.


Matriz de confusión con DenseNet121 en proceso de detección de la RD con conjunto de prueba.



Fuente: Los autores.

Figura 13.

Matriz de confusión obtenida con EfficientNetB0 en el proceso de detección de la RD con conjunto de prueba.



Fuente: Los autores.

Para la interpretación de dichas matrices se considera que “0” corresponde a aquellas imágenes que no tienen RD, mientras que la etiqueta “1” corresponde a aquellas que tienen indicios de la enfermedad.

Así, se logra deducir que el modelo estructurado con la red pre entrenada EfficientNetB0 realizó las predicciones más acertadas. Esto debido a que de las 546 imágenes totales usadas para las pruebas: 269 pertenecen a la clase 0 (Sin RD) y 277 pertenecen a la clase 1 (Con RD). Así:

- Con la red ResNet50, de las 269 imágenes de clase 0 se predijeron 263 correctamente, mientras que de las 277 de clase 1 se predijeron 258 correctamente, siendo así un total de 521 imágenes que se predijeron correctamente.
- Con la red Xception, de las 269 imágenes de clase 0 se predijeron 250 correctamente, mientras que de las 277 de clase 1 se predijeron 264 correctamente, siendo así un total de 514 imágenes que se predijeron correctamente.
- Con la red VGG16, de las 269 imágenes de clase 0 se predijeron 263 correctamente, mientras que de las 277 de clase 1 se predijeron 260 correctamente, siendo así un total de 523 imágenes que se predijeron correctamente.
- Con la red DenseNet121, de las 269 imágenes de clase 0 se predijeron 260 correctamente, mientras que de las 277 de clase 1 se predijeron 264 correctamente, siendo así un total de 524 imágenes que se predijeron correctamente.

- Con la red EfficientNetB0, de las 269 imágenes de clase 0 se predijeron 264 correctamente, mientras que de las 277 de clase 1 se predijeron 265 correctamente, siendo así un total de 529 imágenes que se predijeron correctamente.

Tabla 4.

Comparativa de resultados con trabajos similares del estado del arte.

Autor	Modelo propuesto	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	Puntaje F1 (%)	Kappa (%)	AUC (%)
Nuestro Modelo	EfficientNetB0	96.89	98.15	95.67	98.14	96.9	93.77	96.9
Bodapati et. al.	VGG16 (DNN)	97.82	98.00	98.00	-	98.00	-	98.00
Adriman et. al.	ResNet	96.35	-	-	-	-	-	-
Adriman et. al.	Densenet 121	84.05	-	-	-	-	-	-
Khalifa. et. al	VGG 19	97.4	94.64	95.76	-	95.2	-	-
Khalifa. et. al	VGG 16	97.8	95.19	96.02	-	95.6	-	-
(Dekhil et al., 2019)	VGG16	94.37	-	-	-	-	-	-

Fuente: Los autores.

Finalmente, haciendo la debida comparación (Principalmente en la exactitud de 96.89% alcanzada) con trabajos destinados a la detección de la Retinopatía Diabética, en la [Tabla 4](#) se aprecia que, en esta etapa de pruebas preliminares del proyecto se logran resultados que superan los trabajos de algunos autores como lo son Adriman y Dekhil, con 93.35% y 94.37%, y estando muy cerca de los valores de 97.8% de Khalifa y 97.82% de Bodapati. Esto demostrando que aún se podía incursionar en técnicas y métodos que permitirían la estructuración de un modelo más robusto y capaz, como se verá en la siguiente sección.

Metodología para la Elaboración de la Red Neuronal Convolutiva Final (Detección y Clasificación de la Retinopatía Diabética)

Habiendo alcanzado resultados satisfactorios, como se indicó en la sección anterior, se procedió a experimentar con variantes en la metodología que se llevaba hasta el momento. En esta sección se indican los aspectos que cambiamos en la elaboración del proyecto, siendo el más interesante el hecho de no limitar los resultados a una clasificación binaria, es decir, dar un veredicto de si hay o no hay indicios de RD, sino que de ser positivo el diagnóstico, se pueda tener también un diagnóstico del nivel en el que se encuentra la enfermedad (Clasificación de la RD).

Descripción y Procesamiento del Conjunto de Imágenes

Continuamos usando las imágenes obtenidas de la competencia de APTOS con las que se trabajó, conservando las mismas proporciones de distribución de imágenes establecidas en las pruebas del capítulo anterior y como lo muestran las [Figuras 6.a](#) y [6.b](#). Por otra parte, para el procesamiento de estas imágenes, se mejoró la función de recorte de bordes oscuros con la que se eliminan las áreas negras poco informativas que son evidentes por medio de la ubicación del centro de la imagen y así evitar recortar parte de la retina, también, se ajustó el tamaño de las imágenes a 320x320 píxeles para reducir la pérdida de información debido a la disminución de los tamaños en las imágenes. Además, se optó por aplicarle a todo el conjunto de imágenes la técnica de Ecuilización de histograma adaptativo limitado de contraste (*CLAHE*, por sus siglas en inglés) (*OpenCV: Histograms - 2: Histogram Equalization*, n.d.), mediante el cual, como su nombre lo indica, se mejoran aspectos de brillo y contraste en las imágenes para obtener una mejor calidad y realce de las características de la retina, ya que algunas de estas imágenes no

poseen el brillo o nitidez óptimo para que el sistema detecte las lesiones causadas por la RD en la retina y con este algoritmo sí se permiten apreciar dichas lesiones. La [Figura 14](#) posibilita valorar la mejora en la calidad, contraste y nitidez de las imágenes antes y después de aplicarle el preprocesamiento.

Metodología Propuesta

La manera en la que se procedió para la elaboración de estas pruebas varía significativamente con respecto a la presentada anteriormente, teniendo así que:


- Se continuó haciendo uso de la técnica del Transfer Learning, ya que las redes preentrenadas sirven como un buen punto de partida para la estructuración de este tipo de modelos usados en el tratamiento y clasificación de imágenes. Esta vez se realizaron entrenamientos con un mayor número de redes preentrenadas, siendo estas: Xception, VGG16, VGG19, DenseNet121, DenseNet169, InceptionV3, ResNet50, ResNet101, InceptionResNetV2, EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3.
- Para Feature Extraction, se omitió el “congelamiento de capas” y se decidió dejar que las redes elaboradas se entrenen de principio a fin, logrando que aprendan a reconocer de forma más específica las características fundamentales de las imágenes de fondo de ojo, con la contra de que los entrenamientos tardarán relativamente más en completarse. Aun así, sigue siendo esencial el hecho de reemplazar el clasificador predeterminado de la red importada por un clasificador personalizado para la tarea. (Ver [Figura15a](#))
- La [Figura 15b](#) ejemplifica la estructura de la red haciendo uso del modelo EfficientNtB0, en la cual destacamos la inclusión de una capa “Flatten” que ayuda a interpretar las imágenes como vectores de datos para mayor facilidad de interpretación por parte de la red y una “Dense” de 64 Neuronas para que la red haga analice un poco más la

información antes de llegar a la última capa de predicciones. Además, es de suma importancia destacar el cambio del número de Neuronas en la última capa “Dense”, siendo ahora de 5, correspondiente a los 5 niveles de Retinopatía que se desean reconocer.

- Al no aplicarse el “congelamiento de capas”, se descarta también la posibilidad de usar Fine Tuning.
- El Data Augmentation se mantendrá igual al utilizado anteriormente

Figura 14.

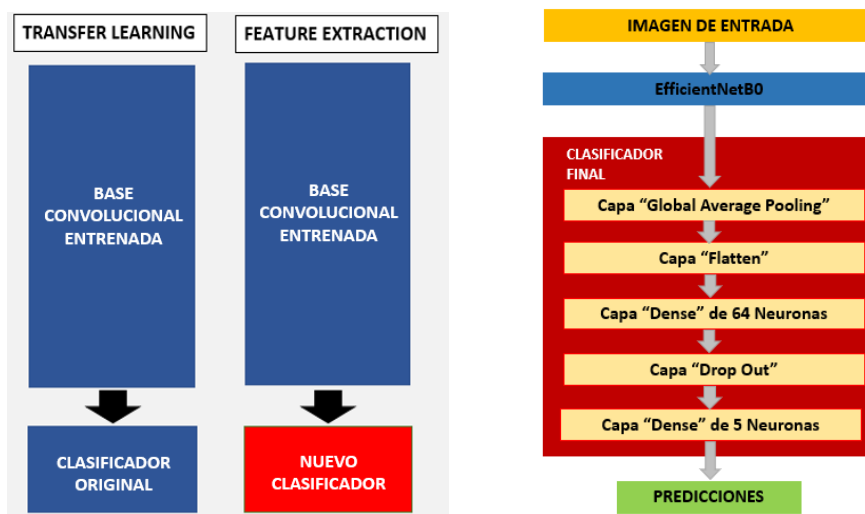
Imágenes antes y después del procesamiento: a) Imagen originales, b) Imagen procesada con el algoritmo de CLAHE.



Fuente: Conjunto de imágenes “APTOS 2019 Blindness Detection” [20] y los autores.

Figura 15.

Diagramas de bloque con la estructura de la red: a) Diagrama de la estructura simplificada de la CNN, b) Diagrama de construcción de la nueva red a entrenar usando EfficientNetB0 para el Aprendizaje por transferencia.



Fuente: Los Autores

Para los parámetros bajo los que se realizaron los entrenamientos de las redes, existen unas pequeñas mejoras que optimizan el tiempo de duración y la calidad de estos:

- Optimizador tipo Adam con un Learning Rate inicial de $1e-4$, además se hizo uso del callback “ReduceLRonPlateau”, el cual permite modificar el Learning Rate si las métricas durante el entrenamiento no mejoran. Para este caso se usó como métrica de referencia el “val_loss” indicándole que, si en 3 epochs no mejora, el Learning Rate deberá multiplicarse por un factor de 0.1 para los siguientes epochs.
- El tamaño de lote (Batch Size) fue de 4.
- Se estipularon 30 epochs para cada entrenamiento, además se hizo uso del callback “EarlyStopping”, el cual detiene el entrenamiento si las métricas no mejoran al cabo de

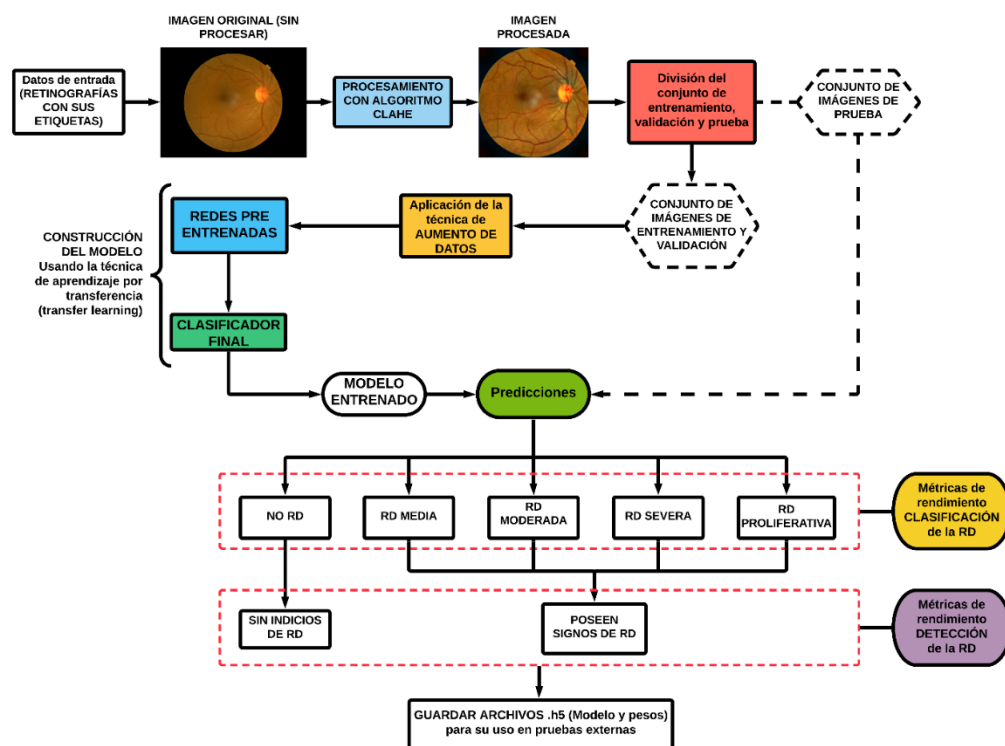
cierto número de epochs. Para este caso se usó como métrica de referencia el “val_loss” indicándole que, si en 8 epochs no mejora, el entrenamiento se detendrá, con lo cual se podrán realizar 2 reducciones de Learning Rate antes de detener definitivamente el entrenamiento.

- Función de “loss” establecida como binary_crossentropy
- Para “metrics” se indicó únicamente “accuracy”.

Así, la [Figura 16](#) sintetiza la nueva metodología seguida para la construcción de las redes.

Figura 16.

Diagrama de flujo con el nuevo enfoque seguido para la detección y clasificación de la RD.



Fuente: Los autores.

Resultados

Como se observa en la [Figura 16](#), las redes en primera medida reciben como entrada las imágenes originales (Sin procesar), luego estas imágenes pasan por una técnica de preprocesamiento en la cual se le recorta los bordes negros a la imagen haciendo uso de un algoritmo que ubica el centro de la retina y con base a esto calcula el ancho y alto de ella para así recortar todo lo que quede por fuera de esta. Luego el algoritmo de CLAHE mejora el contraste de la imagen pasándola primero a escala de grises mediante la transformación de los valores mediante la ecualización de histograma adaptativo por contraste limitado. Posteriormente realizan predicciones con base a los 5 niveles de RD que se les pasaron a las redes pre entrenadas en el entrenamiento tanto por las imágenes como por sus respectivas etiquetas y así, logrando su respectiva evaluación de rendimiento haciendo uso de las métricas explicadas en el estado del arte. Posteriormente se agrupan las clases 1, 2, 3 y 4 en un solo grupo para la correspondiente evaluación biclase (detección de la RD).

Clasificación de la Retinopatía Diabética

De los resultados mostrados en la [Tabla 5](#), se observa que el modelo entrenado con *VGG16* como red pre-entrenada base realizó predicciones más acertadas que el resto de las redes, estas métricas fueron calculadas teniendo en cuenta la matriz de confusión de la [Figura 17](#), en la cual se pueden observar los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos para cada nivel. También se puede observar que al sistema le cuesta en gran manera detectar las imágenes etiquetas como nivel 3, es decir, RD Severa; recordemos que este nivel es el que menor número de imágenes posee (Ver [Figura 6a](#)) con 5.3% del valor total de imágenes que conforman el conjunto de imágenes, lo cual es un indicador de que el desbalance que posee

un conjunto de datos en el cual la distribución de estos sea de tipo categórica influye proporcionalmente en la calidad del entrenamiento de una red neuronal convolucional aplicada a la detección y clasificación de características en imágenes.

Tabla 5.


Resultados de los modelos evaluados para la clasificación de la RD.

Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	Coefficiente kappa (%)
Xception	81.87	81.6	81.87	81.47	72.5
VGG16	83.52	82.68	83.52	82.52	74.71
VGG19	81.32	81.74	81.32	79.93	71.23
DenseNet121	82.05	82.61	82.05	81.78	72.81
DenseNet169	82.05	82.32	82.05	81.52	72.64
InceptionV3	81.87	81.81	81.87	81.50	72.45
ResNet50	81.87	82.04	81.87	81.14	72.37
ResNet101	82.78	82.57	82.78	82.00	73.64
InceptionResNetV2	82.42	81.85	82.42	81.87	73.30
EfficientNetB0	80.95	80.71	80.95	80.41	70.90
EfficientNetB1	81.50	82.27	81.50	80.62	71.87
EfficientNetB2	78.02	77.03	78.02	76.92	66.19
EfficientNetB3	79.49	79.80	79.49	79.13	68.91

Fuente: Los autores.

Figura 17.

Matriz de confusión para la clasificación de la RD haciendo uso de la red VGG16.



Fuente: Los autores.

Así mismo en la [Tabla 6](#) exponemos los resultados alcanzados por otros trabajos disponibles en el estado del arte y que también usaron el conjunto de imágenes de APTOS 2019 Blindness Detection para tareas de clasificación de la RD. Esto lo hacemos para compararnos con dichos trabajos y medir el rendimiento y desempeño de nuestro sistema frente a los propuestos por otros autores.

Tabla 6.

Resultados de los modelos propuestos en el estado del arte para la clasificación de la RD.

Autor	Modelo	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	F1 (%)	Kappa (%)
Nuestro Modelo	VGG16	83.52	82.68	83.52	-	82.52	74.71
Bodapati et al.	VGG16	82.54	82	83	-	82	-
Pak et al.	DenseNet 121	-	-	-	-	-	69
Pak et al.	ResNet50	-	-	-	-	-	70.8
Pak et al.	ResNet101	-	-	-	-	-	73.4
(Nguyen et al., 2020)	VGG16 y VGG19	82	-	80	82	-	-

(Kassani et al., 2019)	Xception modificada	83.09	-	88.04	87	-	-
(Harikrishnan et al., 2020)	NASNet	82	-	-	-	-	-
(Gangwar & Ravi, 2021)	Híbrido de Inception ResNet-v2	82.18	-	-	-	-	-
(Dekhil et al., 2019)	VGG16	77	-	-	-	-	78
(Bodapati et al., 2021b)	Enfoque de incorporación de características	84.31	-	-	-	84	75.87

Fuente: Los autores.

Se observa que en materia de exactitud de precisión superamos los trabajos de Bodapati et al, Nguyen et. al, Kassani et al, Harikrishnan et al, Gangwar & Ravi y Dekhil et al. Esto es un indicador de que logramos superar casi que en su totalidad a todos los autores y en adición, nuestro modelo se encuentra muy cercano al modelo con el valor más alto alcanzado, el de Bodapati et al, con una diferencia de exactitud de precisión de 0.79%.

Cabe resaltar que estos estudios son realizados por personas expertas en el tema y con un alto grado de estudios en esta área de la ciencia, lo cual advierte que nuestro modelo-solución a pesar de ser ejecutado en un ambiente de desarrollo sencillo y sin mucha potencia computacional logra el principal objetivo que es clasificar correctamente la RD y, además, supera dichos objetivos compitiendo con los resultados actuales disponibles en el estado del arte.

Detección de la Retinopatía Diabética

A partir de las métricas mostradas en la [Tabla 7](#), concluimos que el modelo entrenado con *DenseNet169* como red pre-entrenada base nuevamente realizó predicciones más acertadas en la

tarea de detección de la RD, lo cual se aprecia mejor en la matriz de confusión de la [Figura 18](#), en esta figura podemos observar que nuestro sistema solo presenta 2 falsos negativos y 5 falsos positivos, lo cual señala que logramos obtener un sistema bastante robusto, en materia de detección de la RD, de forma exitosa.

Tabla 7.


Resultados de los modelos evaluados para la detección de la RD con el nuevo enfoque.

Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	Puntaje F1 (%)	Kappa (%)	AUC (%)
Xception	97.80	98.18	97.47	98.14	97.83	95.6	97.80
VGG16	98.35	98.91	97.83	98.88	98.37	96.70	98.36
VGG19	97.80	96.17	99.64	95.91	97.87	95.60	97.77
DenseNet121	97.62	97.83	97.47	97.77	97.65	95.24	97.62
DenseNet169	98.72	98.21	99.28	98.14	98.74	97.43	98.71
InceptionV3	98.35	97.86	98.92	97.77	98.38	96.70	98.34
ResNet50	97.80	97.83	97.83	97.77	97.83	95.60	97.80
ResNet101	97.80	97.83	97.83	97.77	97.83	95.60	97.80
InceptionResNetV2	97.80	98.53	97.11	98.51	97.82	95.60	97.81
EfficientNetB0	97.61	98.18	97.11	98.14	97.64	94.24	97.62
EfficientNetB1	98.16	97.85	98.56	97.77	98.20	96.34	98.16
EfficientNetB2	95.05	98.45	91.70	98.51	94.95	90.12	95.10
EfficientNetB3	97.61	98.18	97.11	98.14	97.64	95.24	97.62

Fuente: Los autores.

Figura 18.

Matriz de confusión obtenida en la detección de la RD con DenseNet169.



Fuente: Los autores.

En la [Tabla 8](#) presentamos de igual manera los trabajos disponibles en el estado del arte que hicieron uso del conjunto de imágenes de APTOS 2019 Blindness Detection y que de igual forma se enfocaron en la tarea de detección de la RD.

Tabla 8.

Resultados de los modelos propuestos en el estado del arte para la detección de la RD.

Autor	Modelo	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	Puntaje F1 (%)	Kappa (%)	AUC (%)
Nuestro Modelo	DenseNet169	98.72	98.21	99.28	98.14	98.74	97.43	98.71
Bodapati et al.	VGG16	97.82	98	98	-	98	-	-
(Adriman et al., 2021)	ResNet34 (Personalizada)	96.35	-	-	-	-	-	-
(Adriman et al., 2021)	DenseNet	84.05	-	-	-	-	-	-
(Vives-Boix & Ruiz-Fernández, 2021)	InceptionV3	95.56	98.90	90	-	94.24	-	-
(Khalifa et al., 2019)	VGG16	97.80	-	-	-	-	-	-

Fuente: Los autores.

Como se puede observar, nuestro sistema usando la red de *DenseNet169* obtuvo unos excelentes resultados en todas las métricas, tanto así que logramos superar a todos los trabajos del estado del arte en términos de exactitud, sensibilidad y puntaje F1. Con nuestra exactitud de precisión de 98.72% logramos superar en un 0.51% la exactitud más alta alcanzada en el estado del arte la cual corresponde a Bodapati et al. con 97.82%. Así mismo, la precisión que alcanzamos nosotros, la cual es de 98.21% no se encuentra muy alejada de las demás precisiones alcanzadas, solo fue superada por Vives-Boix et al. con un 0.69% de diferencia. Finalmente, en sensibilidad y puntaje F1 superamos los resultados más altos alcanzados, los cuales corresponden a Bodapati et al. que obtuvo 98% en ambas métricas mientras que nosotros alcanzamos 99.28% y 98.74% para la sensibilidad y puntaje F1, respectivamente. Esto es un logro muy importante ya que mostramos que nuestro sistema no es solamente robusto para tareas de clasificación, sino que en la tarea de detección es la mejor hasta ahora presentada.

Pruebas Adicionales con Otros Conjuntos de Imágenes.

A manera de validación de la metodología propuesta se realizaron pruebas con otros 2 conjuntos de datos: El primero es MESSIDOR (*Messidor - ADCIS*, n.d.), que contiene 1200 imágenes de fondo de ojo repartidas entre las clases 0, 1, 2, y 3, mientras que el segundo dataset usado fue MESSIDOR-2 (*Messidor-2 - ADCIS*, n.d.) que consta de 1748 imágenes. Estas no cuentan con un sistema de etiquetado oficial, por lo cual tuvimos que basarnos en un estudio externo para la clasificación de estas (*MESSIDOR-2 DR Grades / Kaggle*, n.d.), repartiéndose así entre las clases 0, 1, 2, 3 y 4, aunque para estas pruebas se combinaron las clases 3 y 4 debido a que el número de muestras de estas era muy escaso (75 y 35 respectivamente).

La [Tabla 9](#) resume los resultados obtenidos con las diversas redes probadas para la Clasificación de la RD haciendo uso del conjunto de datos de MESSIDOR.

Tabla 9.

Resultados de los modelos evaluados para la clasificación de la RD usando las imágenes de MESSIDOR.

Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	kappa (%)
Xception	76.11	72.46	76.11	73.61	64.08
VGG16	71.11	69.02	71.11	67.42	54.27
VGG19	73.33	72.97	73.33	72.92	61.87
DenseNet121	76.11	70.64	76.11	72.55	63.70
DenseNet169	76.11	74.31	76.11	74.6	64.39
InceptionV3	75.56	75.48	75.56	73.81	63.10
ResNet50	75.00	74.72	75.00	73.79	62.60
ResNet101	76.11	73.17	76.11	73.80	64.00
InceptionResNetV2	72.22	68.78	72.22	69.31	58.02
EfficientNetB0	73.33	70.06	73.33	71.54	60.50
EfficientNetB1	76.67	74.38	76.67	75.10	65.29
EfficientNetB2	78.89	76.50	78.89	76.76	68.30
EfficientNetB3	75.00	73.80	75.00	74.31	63.56

Fuente: Los autores.

La [Tabla 10](#) resume los resultados obtenidos con las diversas redes probadas para la Clasificación de la RD haciendo uso del conjunto de datos de MESSIDOR-2.

Tabla 10.

Resultados de los modelos evaluados para la clasificación de la RD usando las imágenes de MESSIDOR-2.


Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	kappa (%)
Xception	75.48	73.54	75.48	72.85	57.14
VGG16	76.25	74.47	76.25	72.77	55.12
VGG19	78.93	76.68	78.93	77.37	62.13
DenseNet121	75.86	74.26	75.86	74.89	58.47
DenseNet169	80.46	77.96	80.46	78.67	65.19
InceptionV3	77.78	75.28	77.78	74.18	57.56
ResNet50	80.08	77.98	80.08	77.75	63.70
ResNet101	76.25	71.59	76.25	72.71	55.88
InceptionResNetV2	78.54	75.70	78.54	75.27	60.50
EfficientNetB0	76.25	72.91	76.25	73.64	56.75
EfficientNetB1	77.39	75.58	77.39	76.20	59.98
EfficientNetB2	80.46	76.10	80.46	76.11	63.44
EfficientNetB3	80.46	76.76	80.46	76.98	64.41

Fuente: Los autores

De la serie de resultados anteriores, se destacan las redes de EfficientNetB2 y DenseNet169 como las que consiguieron mejores resultados en la tarea de CLASIFICACIÓN para los datasets de MESSIDOR y MESSIDOR-2. Las predicciones hechas por dichas redes se aprecian en las Figuras [19](#) y [20](#).

Figura 19.

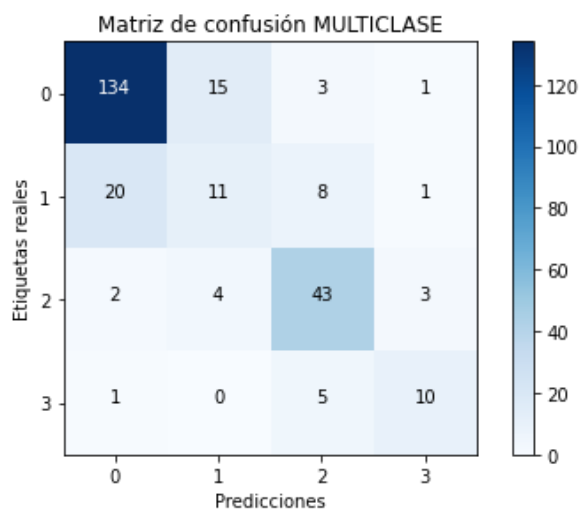
Matriz de confusión para la clasificación de la RD con imágenes de MESSIDOR haciendo uso de la red EfficientNetB2.



Fuente: Los autores.

Figura 20.

Matriz de confusión para la clasificación de la RD con imágenes de MESSIDOR-2 haciendo uso de la red DenseNet169.



Fuente: Los autores.

En cuanto a temas de Detección, la [Tabla 11](#) resume los resultados obtenidos con las diversas redes probadas para la Detección de la RD haciendo uso del conjunto de datos de MESSIDOR.

Tabla 11.

Resultados de los modelos evaluados para la detección de la RD usando las imágenes de MESSIDOR.

Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	Puntaje F1 (%)	Kappa (%)	AUC (%)
Xception	84.44	91.67	78.57	91.46	84.62	69.07	85.02
VGG16	78.33	98.36	61.22	98.78	75.47	57.87	80.00
VGG19	83.33	82.08	88.78	76.83	85.29	66.13	82.80
DenseNet121	85.55	95.0	77.55	95.12	85.39	71.39	86.34
DenseNet169	83.89	89.66	79.59	89.02	84.32	67.87	84.31
InceptionV3	84.44	93.75	76.53	93.9	84.27	69.19	85.22
ResNet50	83.33	90.48	77.55	90.24	83.52	66.86	83.90
ResNet101	83.89	91.57	77.55	91.46	83.98	68.00	84.51
InceptionResNetV2	82.78	91.36	75.51	91.46	82.68	65.86	83.49
EfficientNetB0	82.22	86.67	79.59	85.37	82.98	64.44	82.48
EfficientNetB1	85.56	90.91	81.63	90.24	86.02	71.17	85.94
EfficientNetB2	86.11	92.94	80.61	92.68	86.34	72.36	86.65
EfficientNetB3	83.89	85.57	84.69	82.93	85.13	67.55	83.81

Fuente: Los autores

La [Tabla 12](#) resume los resultados obtenidos con las diversas redes probadas para la Detección de la RD haciendo uso del conjunto de datos de MESSIDOR-2.

Tabla 12.

Resultados de los modelos evaluados para la detección de la RD usando las imágenes de MESSIDOR-2.


Red Preentrenada	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Especificidad (%)	Puntaje F1 (%)	Kappa (%)	AUC (%)
Xception	83.9	82.35	77.78	88.24	80.01	66.56	83.01
VGG16	86.97	100.0	68.52	100.0	81.32	71.84	84.26
VGG19	85.44	89.77	73.15	94.12	80.61	69.15	83.63
DenseNet121	83.91	81.73	78.7	87.58	80.19	66.65	83.14
DenseNet169	88.5	92.39	78.7	95.42	85.0	75.78	87.06
InceptionV3	83.52	97.1	62.04	98.69	75.71	64.14	80.36
ResNet50	87.74	95.24	74.07	97.39	83.33	73.87	85.73
ResNet101	83.14	91.03	65.74	95.42	76.34	63.77	80.58
InceptionResNetV2	85.82	92.77	71.30	96.08	80.63	69.75	83.69
EfficientNetB0	85.06	91.57	70.37	95.42	79.58	68.11	82.90
EfficientNetB1	84.67	86.17	75.00	91.50	80.20	67.80	83.25
EfficientNetB2	85.82	97.33	67.59	98.69	79.78	69.40	83.14
EfficientNetB3	87.74	94.19	75.00	96.73	83.51	73.95	85.87

Fuente: Los autores.

De la serie de resultados anteriores, se destacan las redes de EfficientNetB2 y DenseNet169 nuevamente como las que consiguieron mejores resultados en la tarea de DETECCIÓN para los datasets de MESSIDOR y MESSIDOR-2. Las predicciones hechas por dichas redes se aprecian en las Figuras [21](#) y [22](#).

Figura 21.


Matriz de confusión para la detección de la RD con imágenes de MESSIDOR haciendo uso de la red EfficientNetB2.



Fuente: Los autores.

Figura 22.

Matriz de confusión para la detección de la RD con imágenes de MESSIDOR-2 haciendo uso de la red DenseNet169.



Fuente: Los autores.

Los resultados que se muestran en las [Tablas 9, 10, 11 y 12](#), además de la serie de predicciones expuestas en las [Figuras 19, 20, 21 y 22](#) demuestran que las redes elaboradas con la metodología planteada se enfocan como corresponde a la tarea de distinción de imágenes, siendo capaz de hacer predicciones independientemente del conjunto de imágenes que se usen.

Sin embargo, presentan una disminución de la eficiencia debido a que el hecho de tener menos imágenes disponibles para el entrenamiento influye en la capacidad de aprendizaje de la red, en contraste a las que se tienen en el dataset de APTOS (y que, además, MESSIDOR-2 no cuenta con etiquetas oficiales). Esto demuestra que, si se adquiere mayor conocimiento y destrezas en este tipo de proyectos, se podrían realizar ajustes y configuraciones más detalladas para lograr mejores resultados cuando se dispone de conjuntos de datos reducidos.

Conclusiones

Con este trabajo de investigación hemos demostrado y validado que la inteligencia artificial y en específico, las técnicas de Deep Learning, han demostrado tener el potencial suficiente para desempeñar labores que requieran del análisis y procesamiento de imágenes, en este caso dirigido a un campo de la medicina como lo es el diagnóstico temprano de la enfermedad ocular conocida como Retinopatía Diabética en base a los diversos síntomas que se manifiestan a nivel de la retina. De la misma manera resulta muy viable la utilización de esta novedosa tecnología en otras áreas de trabajo, sin limitarse únicamente al campo médico, pudiendo adaptarse según el objeto de estudio que se tenga. No obstante, las técnicas de Deep Learning no ha sido explotado en su totalidad, por lo que aún existen innumerables posibilidades para su uso y que, con el correr de los años y a medida que se estudien las múltiples funcionalidades que puede brindar, surgirán modelos capaces de procesar situaciones de naturaleza más compleja, llegando a contribuir en gran medida a las labores de los profesionales en lo que a tiempo, costo y precisión se refiere.

En lo que respecta al impacto social que puede generar, es cuestión de familiarizar a los profesionales con este tipo de métodos, siendo muy importante darles a conocer los grandes beneficios que presentan los sistemas desarrollados, ya que, en el caso de la detección de una enfermedad tan perjudicial como lo es la Retinopatía Diabética, es muy importante el impacto que puede generar la implementación de dichos sistemas en el sistema de salud actual, permitiendo a más personas acceder a un diagnóstico confiable y en menor tiempo por un costo más reducido; esto generará un incremento considerable de la cantidad de pacientes

diagnosticados de manera oportuna, lograr evitar numerosos casos de ceguera que pudieron ser tratados a tiempo y, en consecuencia, una mejoría en la calidad de vida de la población.

Ahora bien, como mencionamos anteriormente, el diagnóstico temprano de la RD es esencial para evitar un daño mayor a la visión; es por esto que desde el ámbito de la visión por computadora hemos propuesto una alternativa de solución a este problema con la experimentación de diferentes redes neuronales pre entrenadas disponibles de la librería de Keras diseñadas específicamente para tareas de detección y clasificación a las cuales les introdujimos un clasificador final personalizado de acuerdo a la tarea que esperamos que la red efectúe (la detección de la RD en imágenes de retina), dichas redes las entrenamos con el conjunto de datos público de APTOS 2019 Blindness Detection obteniendo resultados muy desafiantes y competitivos en comparación con los resultados obtenidos por otros trabajos del estado del arte disponibles a la fecha que usaron el mismo conjunto de imágenes que nosotros. La mejor experimentación que obtuvimos alcanzó un valor de exactitud del 98.72%, una precisión de 98.21%, una sensibilidad de 99.28%, una especificidad de 98.14%, un puntaje F1 de 98.74%, un coeficiente kappa de 97.43% y un área bajo la curva (AUC, por sus siglas en inglés) de 98.71% para tareas de detección de la RD usando la red de DenseNet169; para tareas de clasificación nuestra mejor experimentación fue con la red de VGG16, en la que obtuvimos unas métricas de rendimiento de 83.52% de exactitud, 82.68% de precisión, 83.52% de sensibilidad, 82.52% para el puntaje F1 y 74.71% para el coeficiente kappa, lo cual indica que es una red bastante robusta para dicho fin a pesar de ser una propuesta de Deep Learning sencilla comparada con las propuestas presentadas en el estado del arte, en la que son redes mucho más complejas y estructuradas y sus autores contaron con recursos y conocimientos más especializados en el tema

que permitan detallar y pulir en su totalidad una CNN. Aun así, para la tarea de clasificación logramos igualar dichos resultados y para la tarea de detección logramos superar dichos resultados disponibles en el estado del arte, por lo que consideramos este trabajo de investigación como una excelente línea base para futuras investigaciones en el campo de la detección automatizada aplicada a la RD por medio de técnicas de Aprendizaje Profundo (Deep Learning).

Referencias

- ADDIN Mendeley Bibliography CSL_BIBLIOGRAPHY Abramoff, M. D., Lou, Y., Erginay, A., Clarida, W., Amelon, R., Folk, J. C., & Niemeijer, M. (2016). Improved Automated Detection of Diabetic Retinopathy on a Publicly Available Dataset Through Integration of Deep Learning. *Investigative Ophthalmology & Visual Science*, 57(13), 5200–5206. <https://doi.org/10.1167/iovs.16-19964>
- Adriman, R., Muchtar, K., & Maulina, N. (2021). Performance Evaluation of Binary Classification of Diabetic Retinopathy through Deep Learning Techniques using Texture Feature. *Procedia Computer Science*, 179, 88–94. <https://doi.org/10.1016/j.procs.2020.12.012>
- Aggarwal, M., & Khare, V. (2015). *Automatic localization and contour detection of Optic disc*. <https://doi.org/10.1109/ICSPCom.2015.7150686>
- APTOS : Eye Preprocessing in Diabetic Retinopathy | Kaggle*. (n.d.). Retrieved April 5, 2021, from <https://www.kaggle.com/ratthachat/aptos-eye-preprocessing-in-diabetic-retinopathy?scriptVersionId=20340219>
- APTOS 2019 Blindness Detection | Kaggle*. (n.d.-a). Retrieved April 30, 2021, from <https://www.kaggle.com/c/aptos2019-blindness-detection/>
- APTOS 2019 Blindness Detection | Kaggle*. (n.d.-b). Retrieved April 1, 2021, from <https://www.kaggle.com/c/aptos2019-blindness-detection/data>
- Arunkumar, R., & Karthigaikumar, P. (2017). Multi-retinal disease classification by reduced deep learning features. *Neural Computing and Applications*, 28(2), 329–334. <https://doi.org/10.1007/s00521-015-2059-9>
- Asiri, N., Hussain, M., Al Adel, F., & Alzaidi, N. (2019). Deep learning based computer-aided

- diagnosis systems for diabetic retinopathy: A survey. *Artificial Intelligence in Medicine*, 99(December 2018), 101701. <https://doi.org/10.1016/j.artmed.2019.07.009>
- Auccahuasi, W., Flores, E., Sernaque, F., Cueva, J., Diaz, M., & Oré, E. (2020). Recognition of hard exudates using Deep Learning. *Procedia Computer Science*, 167(2019), 2343–2353. <https://doi.org/10.1016/j.procs.2020.03.287>
- Badar, M., Haris, M., & Fatima, A. (2020). Application of deep learning for retinal image analysis: A review. *Computer Science Review*, 35, 100203. <https://doi.org/10.1016/j.cosrev.2019.100203>
- Bodapati, J. D., Shaik, N. S., & Naralasetti, V. (2021a). Composite deep neural network with gated-attention mechanism for diabetic retinopathy severity classification. *Journal of Ambient Intelligence and Humanized Computing*, 1–15. <https://doi.org/10.1007/s12652-020-02727-z>
- Bodapati, J. D., Shaik, N. S., & Naralasetti, V. (2021b). Deep convolution feature aggregation: an application to diabetic retinopathy severity level prediction. *Signal, Image and Video Processing*, 1–8. <https://doi.org/10.1007/s11760-020-01816-y>
- Cerda, J. L., & Villarroel Del, L. P. (2008). Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa. *Rev Chil Pediatr*, 79 (1), 54–58.
- Chetoui, M., & Akhloufi, M. A. (2020). Explainable end-to-end deep learning for diabetic retinopathy detection across multiple datasets. *Journal of Medical Imaging*, 7(4), 1–25. <https://doi.org/10.1117/1.JMI.7.4.044503>
- Cuello Navarro, J., Barraza Peña, C., & Escorcia-Gutiérrez, J. (2020). Una revisión de los métodos de Deep Learning aplicados a la detección automatizada de la retinopatía diabética. *Revista SEXTANTE*, 23, 14–33. <https://sextante->

ensb.com/index.php/inicio/article/view/45

Decencière, E., Cazuguel, G., Zhang, X., Thibault, G., Klein, J. C., Meyer, F., Marcotegui, B., Quellec, G., Lamard, M., Danno, R., Elie, D., Massin, P., Viktor, Z., Erginay, A., Lay, B., & Chabouis, A. (2013). TeleOphta: Machine learning and image processing methods for teleophthalmology. *IRBM*, *34*(2), 196–203. <https://doi.org/10.1016/j.irbm.2013.01.010>

Decencière, Etienne, Zhang, X., Cazuguel, G., Lay, B., Cochener, B., Trone, C., Gain, P., Ordonez, R., Massin, P., Erginay, A., Charton, B., & Klein, J.-C. (2014). Feedback on a publicly distributed database: the Messidor database. *Image Analysis & Stereology*, *33*(3), 231–234. <https://doi.org/10.5566/ias.1155>

Dekhil, O., Naglah, A., Shaban, M., Ghazal, M., Taher, F., & Elbaz, A. (2019). Deep Learning Based Method for Computer Aided Diagnosis of Diabetic Retinopathy. *IST 2019 - IEEE International Conference on Imaging Systems and Techniques, Proceedings*, 19–22. <https://doi.org/10.1109/IST48021.2019.9010333>

Diabetes. (n.d.). Retrieved April 30, 2021, from <https://www.who.int/es/news-room/fact-sheets/detail/diabetes>

Diagnóstico de Retinopatía Diabética Aplicando Redes Neuronales Convolucionales | by EAI | Data Science Bolivia | Medium. (n.d.). Retrieved May 4, 2021, from <https://medium.com/data-science-bolivia/diagnóstico-de-retinopatía-diabética-aplicando-redes-neuronales-convolucionales-8dc8328c3ec3>

Drankowska, J., Kos, M., Kościuk, A., Marzęda, P., Boguszewska-Czubara, A., Tylus, M., & Święch-Zubilewicz, A. (2019). MMP targeting in the battle for vision: Recent developments and future prospects in the treatment of diabetic retinopathy. *Life Sciences*, *229*, 149–156. <https://doi.org/https://doi.org/10.1016/j.lfs.2019.05.038>

Escorcia-Gutierrez, J., Torrents-Barrena, J., Romero-Aroca, P., Valls, A., & Puig, D. (2016).

Interactive optic disk segmentation via discrete convexity shape knowledge using high-order functionals. *Frontiers in Artificial Intelligence and Applications*, 288, 39–44.

<https://doi.org/10.3233/978-1-61499-696-5-39>

EyePACS. (n.d.). *EyePACS*. Retrieved October 4, 2020, from <http://www.eyepacs.com/solution>

Farsiu, S., Chiu, S. J., O’Connell, R. V., Folgar, F. A., Yuan, E., Izatt, J. A., & Toth, C. A.

(2014). Quantitative classification of eyes with and without intermediate age-related macular degeneration using optical coherence tomography. *Ophthalmology*, 121(1), 162–172. <https://doi.org/10.1016/j.ophtha.2013.07.013>

Fraser, C., D’Amico, D., Nathan, D., Trobe, J., & Mulder, J. (2017). *Retinopatía diabética: clasificación y características clínicas - UpToDate*.

<https://www.uptodate.com/contents/diabetic-retinopathy-classification-and-clinical-features>

Gangwar, A. K., & Ravi, V. (2021). *Diabetic Retinopathy Detection Using Transfer Learning and Deep Learning* (pp. 679–689). Springer, Singapore. https://doi.org/10.1007/978-981-15-5788-0_64

Getting started. (n.d.). Retrieved April 5, 2021, from https://keras.io/getting_started/

Giancardo, L., Meriaudeau, F., Karnowski, T. P., Li, Y., Garg, S., Tobin, K. W., & Chaum, E.

(2012). Exudate-based diabetic macular edema detection in fundus images using publicly available datasets. *Medical Image Analysis*, 16(1), 216–226.

<https://doi.org/https://doi.org/10.1016/j.media.2011.07.004>

Gondal, W. M., Kohler, J. M., Grzeszick, R., Fink, G. A., & Hirsch, M. (2018). Weakly-supervised localization of diabetic retinopathy lesions in retinal fundus images.

- Proceedings - International Conference on Image Processing, ICIP, 2017-Septe*, 2069–2073. <https://doi.org/10.1109/ICIP.2017.8296646>
- Guisela, E., & Pozo, R. (2019). *ANÁLISIS DE CLASIFICADORES SUPERVISADOS PARA DETECTAR LA ESTRUCTURA VASCULAR EN IMÁGENES RETINIANAS PATOLÓGICAS*. ESCUELA POLITÉCNICA NACIONAL.
- Harikrishnan, V. K., Vijarania, M., & Gambhir, A. (2020). Diabetic retinopathy identification using autoML. In *Computational Intelligence and Its Applications in Healthcare*. Elsevier Inc. <https://doi.org/10.1016/b978-0-12-820604-1.00012-1>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016a). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016b). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-January*, 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>
- Ishtiaq, U., Kareem, S. A., Rahayu, E., & Faizal, M. (2020). Diabetic retinopathy detection through artificial intelligent techniques : a review and open issues. *Multimedia Tools and Applications*, 79, 15209–15252. <https://doi.org/https://doi.org/10.1007/s11042-018-7044-8>
- Kassani, S. H., Kassani, P. H., Khazaeinezhad, R., Wesolowski, M. J., Schneider, K. A., &

- Deters, R. (2019). Diabetic Retinopathy Classification Using a Modified Xception Architecture. *2019 IEEE 19th International Symposium on Signal Processing and Information Technology, ISSPIT 2019*, 0–5.
<https://doi.org/10.1109/ISSPIT47144.2019.9001846>
- Kauppi, T., Kalesnykiene, V., Kamarainen, J.-K., Lensu, L., Sorri, I., Uusitalo, H., Kälviäinen, H., & Pietilä, J. (n.d.). *DIARETDB0: Evaluation Database and Methodology for Diabetic Retinopathy Algorithms*.
Keras Applications. (n.d.). Retrieved April 5, 2021, from <https://keras.io/api/applications/>
- Khalifa, N. E. M., Loey, M., Taha, M. H. N., & Mohamed, H. N. E. T. (2019). Deep transfer learning models for medical diabetic retinopathy detection. *Acta Informatica Medica*, 27(5), 327–332. <https://doi.org/10.5455/aim.2019.27.327-332>
- Kowluru, R. A., & Chan, P.-S. (2008). Capillary Dropout in Diabetic Retinopathy. In *Diabetic Retinopathy* (pp. 265–282). Humana Press. https://doi.org/10.1007/978-1-59745-563-3_11
- Lam, C., Yi, D., Guo, M., & Lindsey, T. (2018). Automated Detection of Diabetic Retinopathy using Deep Learning. *AMIA Joint Summits on Translational Science Proceedings. AMIA Joint Summits on Translational Science, 2017*, 147–155.
<http://www.ncbi.nlm.nih.gov/pubmed/29888061>
- Li, Q, Xie, L., Zhang, Q., Qi, S., Liang, P., Zhang, H., & Wang, T. (2015). A supervised method using convolutional neural networks for retinal vessel delineation. *2015 8th International Congress on Image and Signal Processing (CISP)*, 418–422.
<https://doi.org/10.1109/CISP.2015.7407916>
- Li, Qiaoliang, Feng, B., Xie, L., Liang, P., Zhang, H., & Wang, T. (2016). A cross-modality

- learning approach for vessel segmentation in retinal images. *IEEE Transactions on Medical Imaging*, 35(1), 109–118. <https://doi.org/10.1109/TMI.2015.2457891>
- Lim, G., Cheng, Y., Hsu, W., & Lee, M. L. (2016). Integrated optic disc and cup segmentation with deep learning. *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI, 2016-Janua*, 162–169. <https://doi.org/10.1109/ICTAI.2015.36>
- Maninis, K.-K., Pont-Tuset, J., Arbeláez, P., & Van Gool, L. (2016). Deep Retinal Image Understanding. In S. Ourselin, L. Joskowicz, M. R. Sabuncu, G. Unal, & W. Wells (Eds.), *Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2016* (pp. 140–148). Springer International Publishing.
- Mansour, R. F. (2018). Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy. *Biomedical Engineering Letters*, 8(1), 41–57. <https://doi.org/10.1007/s13534-017-0047-y>
- Mayo Clinic. (2018). *Retinopatía diabética - Síntomas y causas*. <https://www.mayoclinic.org/es-es/diseases-conditions/diabetic-retinopathy/symptoms-causes/syc-20371611>
- Merino Hernandez, M., Jauregui Garcia, M., Agirrezabala Iturralde, J., Urruzola Lizarribar, A., Guibelalde Gonzalez, A., Prat Madrazo, M., Vergara Mitxeltoarena, I., & Soto Ruiz de Gordo, M. (2019). Desarrollo de un software de cribado automático de retinopatía diabética. *International Journal of Integrated Care*, 19(4), 74. <https://doi.org/10.5334/ijic.s3074>
- Messidor-2 - ADCIS*. (n.d.). Retrieved May 6, 2021, from <https://www.adcis.net/en/third-party/messidor2/>
- MESSIDOR-2 DR Grades | Kaggle*. (n.d.). Retrieved May 6, 2021, from https://www.kaggle.com/google-brain/messidor2-dr-grades?select=messidor_data.csv

- Messidor - ADCIS*. (n.d.). Retrieved May 6, 2021, from <https://www.adcis.net/en/third-party/messidor/>
- Ministry of Health. (2016). *Diabetic Retinal Screening, Grading, Monitoring and Referral Guidance*.
- Mittal, K., & Rajam, V. M. A. (2020). Computerized retinal image analysis - a survey. In *Multimedia Tools and Applications* (Vol. 79, Issues 31–32). Multimedia Tools and Applications. <https://doi.org/10.1007/s11042-020-09041-y>
- Mo, J., & Zhang, L. (2017). Multi-level deep supervised networks for retinal vessel segmentation. *International Journal of Computer Assisted Radiology and Surgery*, *12*(12), 2181–2193. <https://doi.org/10.1007/s11548-017-1619-0>
- Montereal, Q. (n.d.). *APTOS 2019: DenseNet Keras Starter / Kaggle*. Retrieved April 5, 2021, from <https://www.kaggle.com/xhlulu/aptos-2019-densenet-keras-starter>
- Mookiah, M. R. K., Acharya, U. R., Chua, C. K., Lim, C. M., Ng, E. Y. K., & Laude, A. (2013). Computer-aided diagnosis of diabetic retinopathy: A review. *Computers in Biology and Medicine*, *43*(12), 2136–2155. <https://doi.org/https://doi.org/10.1016/j.compbiomed.2013.10.007>
- Moreira, F., Schaan, B., Schneiders, J., Reis, M., Serpa, M., & Navaux, P. (2020). *Impacto da Resolução na Detecção de Retinopatia Diabética com uso de Deep Learning*. 494–499. <https://doi.org/10.5753/sbcas.2020.11546>
- Nguyen, Q. H., Muthuraman, R., Singh, L., Sen, G., Tran, A. C., Nguyen, B. P., & Chua, M. (2020). Diabetic retinopathy detection using deep learning. *ACM International Conference Proceeding Series*, 103–107. <https://doi.org/10.1145/3380688.3380709>
- Niemeijer, M., Van Ginneken, B., Cree, M. J., Mizutani, A., Quilicini, G., Sanchez, C. I., Zhang,

- B., Hornero, R., Lamard, M., Muramatsu, C., Wu, X., Cazuguel, G., You, J., Mayo, A., Li, Q., Hatanaka, Y., Cochener, B., Roux, C., Karray, F., ... Abramoff, M. D. (2010). Retinopathy online challenge: Automatic detection of microaneurysms in digital color fundus photographs. *IEEE Transactions on Medical Imaging*, 29(1), 185–195.
<https://doi.org/10.1109/TMI.2009.2033909>
- OpenCV: Histograms - 2: Histogram Equalization*. (n.d.). Retrieved May 6, 2021, from https://docs.opencv.org/master/d5/daf/tutorial_py_histogram_equalization.html
- Orlando, J. I., Prokofyeva, E., Del Fresno, M., & Blaschko, M. B. (2017). An Ensemble Deep Learning Based Approach for Red Lesion Detection in Fundus Images. *Computer Methods and Programs in Biomedicine*. <https://github.com/ignaciorlando/red-lesion-detection>.
- Pak, A., Ziyaden, A., Tukeshev, K., Jaxylykova, A., & Abdullina, D. (2020). *Comparative analysis of deep learning methods of detection of diabetic retinopathy*.
<https://doi.org/10.1080/23311916.2020.1805144>
- Perdomo, O. J., & González, F. A. (2019). A Systematic Review of Deep Learning Methods Applied to Ocular Images. *Ciencia e Ingeniería Neogranadina*, 30(1), 9–26.
<https://doi.org/10.18359/rcin.4242>
- Randive, S. N., Senapati, R. K., & Rahulkar, A. D. (2019). A review on computer-aided recent developments for automatic detection of diabetic retinopathy. *Journal of Medical Engineering and Technology*, 43(2), 87–99.
<https://doi.org/10.1080/03091902.2019.1576790>
- Rudas, J., & Torres, G. S. (2013). Detección de patologías derivadas de las afecciones diabéticas : una revisión del análisis digital de imágenes de retina The detection of

- pathologies from diabetic disease : a review of digital retinal image analysis. *Ingeniería y Desarrollo. Universidad Del Norte.*, 3461.
- Salamat, N., Missen, M. M. S., & Rashid, A. (2019). Diabetic retinopathy techniques in retinal images: A review. *Artificial Intelligence in Medicine*, 97(January 2018), 168–188.
<https://doi.org/10.1016/j.artmed.2018.10.009>
- Samper, N. M., Escorcía-gutierrez, J., Acosta, M. G., & Torres, M. (2020). Metodología de Segmentación de la Estructura Ocular en Imágenes de Fondo de Ojo de Pacientes con Retinopatía Diabética Methodology of Segmentation the Main Retinal Anatomical Structures in Fundus Images from Patients with Diabetic Retinopathy. *Prospectiva*, 18.
<https://doi.org/http://doi.org/10.15665/rp.v18i2.2401>
- Sancho Caparrini, F. (2020). *Aprendizaje Supervisado y No Supervisado*.
<http://www.cs.us.es/~fsancho/?e=77>
- Saranya Rubini, S., Saai Nithil, R., Kunthavai, A., & Sharma, A. (2019). Deep convolutional neural network-based diabetic retinopathy detection in digital fundus images. *Advances in Intelligent Systems and Computing*, 900, 201–209. https://doi.org/10.1007/978-981-13-3600-3_19
- Scanlon, P. H. (2019). Diabetic retinopathy. *Medicine (United Kingdom)*, 47(2), 77–85.
<https://doi.org/10.1016/j.mpmed.2018.11.013>
- Te damos la bienvenida a Colaboratory - Colaboratory*. (n.d.). Retrieved April 6, 2021, from <https://colab.research.google.com/notebooks/intro.ipynb>
- Torres, J. (n.d.). *Deep Learning, Introducción práctica con Keras (SEGUNDA PARTE) - Jordi TORRES.AI*. Retrieved April 5, 2021, from <https://torres.ai/deep-learning-inteligencia-artificial-keras-2a-parte/#AccesoLibro2aParte>

- Vives-Boix, V., & Ruiz-Fernández, D. (2021). Diabetic retinopathy detection through convolutional neural networks with synaptic metaplasticity. *Computer Methods and Programs in Biomedicine*, 106094. <https://doi.org/10.1016/j.cmpb.2021.106094>
- Wu, A., Xu, Z., Gao, M., Buty, M., & Mollura, D. J. (2016). Deep vessel tracking: A generalized probabilistic approach via deep learning. *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, 1363–1367. <https://doi.org/10.1109/ISBI.2016.7493520>
- Xu, K., Feng, D., & Mi, H. (n.d.). Deep Convolutional Neural Network-Based Early Automated Detection of Diabetic Retinopathy Using Fundus Image. *Molecules*. <https://doi.org/10.3390/molecules22122054>
- Zhao, H., Chen, X., Zhang, D., Zhu, W., & Shi, F. (2018). Automatic localization and segmentation of optical disk based on faster R-CNN and level set in fundus image. *10574*, 65. <https://doi.org/10.1117/12.2292950>
- Zilly, J. G., Buhmann, J. M., & Mahapatra, D. (2015). Boosting convolutional filters with entropy sampling for optic cup and disc image segmentation from fundus images. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 9352). Springer Verlag. https://doi.org/10.1007/978-3-319-24888-2_17