

UNIVERSIDAD RICARDO PALMA
ESCUELA DE POSGRADO
MAESTRÍA EN INGENIERÍA INFORMÁTICA CON
MENCIÓN EN INGENIERÍA DE SOFTWARE



**Tesis para optar el Grado Académico de Maestro en Ingeniería
Informática con Mención en Ingeniería de Software**

**DIAGNÓSTICO PRECOZ DE LA RETINOPATÍA DIABÉTICA
UTILIZANDO VISIÓN COMPUTACIONAL**

Autor: Bach. Robalino Gómez, Hernán

Asesor: Mg. Velásquez Núñez, Ángel Augusto

LIMA – PERÚ

2021

DEDICATORIA

Este proyecto de investigación está dedicado a mis padres por el esfuerzo que realizaron en mi formación personal y profesional, así también a mis hijos que han sido la fuerza motivadora para afrontar los nuevos retos que se me han presentado.

AGRADECIMIENTO

Quiero expresar mi agradecimiento al Mg. Ángel Velásquez Núñez, quien ha sido mi asesor y con su apoyo he podido culminar el trabajo de investigación. Además, agradecer a los miembros del jurado y todas aquellas personas, que con sus observaciones y recomendaciones han permitido que pueda corregir y terminar la realización de este trabajo de investigación.

ÍNDICE GENERAL

INTRODUCCIÓN	1
Capítulo I: PLANTEAMIENTO DEL PROBLEMA	3
1.1 Descripción del Problema	3
1.2 Formulación del Problema	6
1.3 Importancia y Justificación del Estudio	8
1.4 Delimitación del estudio	9
1.5 Objetivos de la Investigación	9
1.5.1 Objetivo general	9
1.5.2 Objetivos específicos	9
Capítulo II: MARCO TEÓRICO	11
2.1 Marco histórico	11
2.2 Investigaciones relacionadas con el tema	12
2.3 Estructura teórica y científica que sustenta el estudio	13
2.4 Definición de términos básicos	21
2.5 Fundamentos teóricos y/o mapa conceptual	24
2.6 Hipótesis	28
2.6.1 Hipótesis general	28
2.6.2 Hipótesis específicas	28
2.7 Variables (definición y operacionalización de variables: Dimensiones e indicadores)	29
Capítulo III: MARCO METODOLÓGICO	31
3.1 Tipo, método y diseño de la investigación	31
3.2 Población y muestra	36
3.3 Técnicas e instrumentos de recolección de datos	37
3.4 Descripción de procedimientos de análisis	37
Capítulo IV: RESULTADOS Y ANÁLISIS DE RESULTADOS	39
4.1 Resultados	40
4.2 Análisis de resultados o discusión de resultados	57
CONCLUSIONES Y RECOMENDACIONES	62
REFERENCIAS BIBLIOGRÁFICAS	65

ANEXOS	71
Anexo A: Declaración de autenticidad	71
Anexo B: Autorización de consentimiento para realizar la investigación	72
Anexo C: Matriz de consistencia	73
Anexo D: No se elabora en la investigación	
Anexo E: No se elabora en la investigación	
Anexo F: No se elabora en la investigación	
Anexo Otros	74

INDICE DE TABLAS

Tabla 1. Se muestra la problemática con sus causas y efectos	7
Tabla 2. Variable independiente	29
Tabla 3. Variable dependiente	29
Tabla 4. Matriz de operacionalización	30
Tabla 5. Características de los servidores en el mercado.	41
Tabla 6. Características de diferentes lenguajes de programación.	42
Tabla 7: Cantidad de imágenes preprocesadas	51
Tabla 8: Resultados de la prueba del modelo neuronal propuesto	57
Tabla 9: Costos y tiempos para la detección de la retinopatía diabética	58
Tabla 10: Logro de los objetivos específicos	61

INDICE DE FIGURAS

Figura 1 imagen vista por una persona sana y con retinopatía diabética	5
Figura 2. Una cámara de fondo de teléfono móvil	5
Figura 3. Teléfono inteligente y el accesorio óptico	6
Figura 4. Descripción general de un proceso típico de aprendizaje automático	15
Figura 5. Estructura general de una red neuronal multicapas.	16
Figura 6. Estructura de una red lineal y estructura de una red no lineal.	17
Figura 7. Diagrama de bloques de un sistema ilustrativo de reconocimiento basado en la red neuronal de convolución de cinco capas, desde el parche de imagen hasta la capa de clasificación.	18
Figura 8. Fundus retinal imágenes originales.	20
Figura 9. Imágenes retíales preprocesadas.	20
Figura 10. Componentes del ojo.	21
Figura 11. Mapa conceptual de la variable independiente Visión computacional.	25
Figura 12. Mapa conceptual de la variable dependiente diagnóstico precoz.	28
Figura 13. Procedimiento de evaluación para pacientes diabéticos tipo 1.	33
Figura 14. Procedimiento de evaluación para pacientes diabéticos tipo 2.	34
Figura 15. Configuración de la red neuronal convolucional.	35
Figura 16. Imagen de fondo de ojo con microaneurisma	36
Figura 17. Retinografía con diferentes luminosidades	45
Figura 18. Retinografía con manchas y distorsionada	45
Figura 19. Retinografías con diferente zoom	46
Figura 20. Retinografía con distinta ubicación del nervio óptico	46
Figura 21. Retinografía con imagen cortada	46
Figura 22: Retinografía sin la enfermedad y con la enfermedad	47
Figura 23: Retinografía original	47
Figura 24: Recorte de retinografía	48
Figura 25: Retinografía al 50% gris	49
Figura 26: Aislamiento de borde de retinografía	49
Figura 27: Redimensionamiento de la retinografía	50
Figura 28: Importaciones de bibliotecas importantes	52

Figura 29: Modelo Neuronal en Keras	53
Figura 30: Modelo Neuronal en Keras	56

RESUMEN

De todos los sentidos que tienen los seres humanos tal vez uno de los más importantes es la visión, de ahí el interés de tener sumo cuidado para que nada lo afecte, esto permite preocuparnos para saber que enfermedades pueden afectar o dañar nuestro sentido de la visión. La retinopatía diabética es una de las principales causas de ceguera como complicación de la diabetes a largo plazo. La pérdida permanente de la visión puede evitarse mediante un diagnóstico precoz de los síntomas de la retinopatía diabética, como los exudados retinianos. Este trabajo de investigación propone utilizar la visión computacional, con redes convolucionales, que permita analizar las imágenes de fondo de ojo para detectar la retinopatía diabética.

Existen varias bases de datos disponibles para realizar estos tipos de estudios, entre ellas se tiene: drive, stare, diarectdb0, diarectdb1, mesidor, e_ophtha_MA y Kaggle, para obtener imágenes de ojos que tiene retinopatía diabética e imágenes de ojos sanos. En el estudio decidió por la base de datos Kaggle, porque sus imágenes están más orientada al desarrollo de proyectos orientados al estudio del fondo de ojos.

Los resultados de rendimiento indicaron que se ha tenido una precisión del 80%, el cual es aceptado para estos tipos de proyectos.

En nuestro país se ha avanzado poco en lo que se refiere a la prevención de este tipo de patologías que afectan la visión, pero si se inculca que las personas realicen periódicamente un chequeo de la visión es seguro que estaremos evitando que los casos de patologías de la visión aumenten. El sistema desarrollado es útil para clasificar las imágenes e identificar la retinopatía diabética, por lo que podría ser aplicable para una mayor población de problemas en la visión

Palabras claves: Retinopatía diabética; redes convolucionales; imágenes de fondo de ojo; visión computacional.

ABSTRACT (Keywords)

Of all the senses that human beings have, perhaps one of the most important is vision, hence the interest in taking great care so that nothing affects it, this allows us to worry about what diseases can affect or damage our sense of vision . Diabetic retinopathy is one of the leading causes of blindness as a long-term complication of diabetes. Permanent loss of vision can be avoided by early diagnosis of diabetic retinopathy symptoms, such as retinal exudates. This research work proposes the use of computational vision, with convolutional networks, which allows analysis of the fundus images to detect diabetic retinopathy.

There are several databases available to perform these types of studies, including: drive, stare, diarectdb0, diarectdb1, mesidor, e_ophtha_MA and Kaggle, to obtain images of eyes that have diabetic retinopathy and images of healthy eyes. In the study he decided on the Kaggle database, because his images are more oriented to the development of projects oriented to the study of the fundus.

The performance results indicated an accuracy of 80%, which is accepted for these types of projects.

In our country little progress has been made with regard to the prevention of this type of pathologies that affect vision, but if it is instilled that people periodically carry out a vision checkup, it is certain that we will be preventing cases of pathologies from vision increase. The developed system is useful for classifying images and identifying diabetic retinopathy, so it could be applicable for a larger population of vision problems

Keywords: Diabetic retinopathy; convolutional networks; fundus images; computer vision.

INTRODUCCION

Según lo informado por la Federación Internacional de Diabetes (IDF), con el lanzamiento de la octava edición del Diabetes Atlas de la IDF en el Día Mundial de la Diabetes, un hito de la FID en 2017. Los nuevos números -425 millones de adultos con diabetes en 2017, un estimado de 629 millones en 2045 - subrayar la necesidad de medidas urgentes para abordar la carga económica y social mundial que representa la diabetes. Una persona muere de diabetes cada seis segundos. Incluso en los países de altos ingresos, la diabetes es una de las principales causas de ceguera debido a su complicación en la retina (retinopatía) causada por el daño de los vasos retinianos.

En nuestro país los problemas visuales representan la segunda causa de discapacidad a nivel nacional, se ha estimado, según el Instituto Nacional de Estadística e Información. En el 2016, el 2,9% de la población de 15 y más años de edad fue diagnosticada con diabetes mellitus, manteniéndose en el mismo valor que el 2015. Siendo la población femenina la más afectada (3,2%) respecto a la masculina (2,7%). Asimismo, por región natural, en el 2016, el mayor porcentaje de personas con diabetes fueron las residentes de Lima Metropolitana (4,6%) y en menor porcentaje las residentes de la Sierra (1,8%). Esta enfermedad es una de las principales causas de ceguera, insuficiencia renal, infarto de miocardio y accidente cerebrovascular.

Desde hace tiempo se han hechos investigaciones para desarrollar sistemas informáticos que apoyen a los oftalmólogos a identificar los problemas de la visión, lo que permite mejorar el diagnóstico precoz. Estos sistemas están apoyados por una base datos que se actualiza con los diversos casos que van apareciendo relacionados a los problemas de la visión, permitiendo que se mejore la toma de decisiones relacionado a problemas visuales.

Este trabajo busca apoyar la labor del oftalmólogo, para ellos se ha considerado en el desarrollo del sistema la misma terminología que utiliza el oftalmólogo, pero la base tecnológica es de Inteligencia Artificial (IA), que ayudara a identificar los problemas de la visión a partir de la digitalización de la imagen capturada del ojo. Las técnicas utilizadas para identificar las características de un problema de visión y el uso de las Redes Neuronales

Artificiales (RNA) que permitan clasificar el tipo de patología, va asegurar que el sistema sea útil al oftalmólogo.

Las RNA pertenecen a las tecnologías computacionales que se pueden utilizar en diferentes campos: Medicina, Comercial, Militar, etc. Son utilizadas porque son confiables, eficientes y presentan una alta tolerancia de fallas y su implementación es de bajo costo.

El estudio de investigación considera cuatro capítulos:

- En el primer capítulo, se presenta la descripción y formulación del problema; importancia y justificación del estudio, indicando las delimitaciones del estudio y los objetivos definidos, todo ellos pretenden informar al lector sobre el problema que representa la retinopatía diabética.
- El segundo capítulo, se compone del marco teórico que sustenta el estudio e incluye las investigaciones relacionadas con el tema, la definición de los términos básicos, las hipótesis y sus respectivas variables.
- En el tercer capítulo está el marco metodológico donde se presenta el diseño de investigación, población y muestra, técnicas e instrumentos, así como el proceso de recolección de datos.
- En el cuarto capítulo se presentan los resultados y análisis de los resultados obtenidos en la investigación
- Seguidamente se presentan las conclusiones y recomendaciones al finalizar el estudio.
- Finalmente se presentan las referencias bibliográficas que se han considerado en el desarrollo de este estudio. Cuando se realizó el trabajo de investigación no se encontró fuentes bibliográficas nacionales que sean de maestría y que estén orientadas en la misma línea del estudio realizado.

Capítulo I: PLANTEAMIENTO DEL PROBLEMA

1. Planteamiento del problema

La mayoría de los oftalmólogos actuales identifican los tipos de enfermedades mediante observación visual e interpretación. Debido a que el diagnóstico preciso es imprescindible para un tratamiento oportuno exitoso, la identificación se puede mejorar notablemente mediante el uso de sistemas de diagnóstico asistido por computadora. Con la incorporación de la tecnología se ha logrado un diagnóstico no invasivo de diversas anomalías retinianas, como el glaucoma, la degeneración macular y el edema macular diabético.

El principal inconveniente en la identificación de la retinopatía diabética se presenta por la falta de un diagnóstico precoz, la mayoría de los diagnósticos no es difícil cuando el estado es avanzado, por los síntomas que son claramente visibles como presión ocular avanzada, pérdida de la visión, etc. Existen estudios que, incluyendo inteligencia artificial, presentan dificultades en la correcta localización de la misma y se centran esencialmente en detectar zonas del ojo con pérdida visual.

Los ojos son órganos dinámicos y sensibles que están conectados al resto del cuerpo a través de los sistemas circulatorio y nervioso. Esta significa que las enfermedades que se originan de un órgano dentro del cuerpo pueden afectar indirectamente a los ojos. Aunque los ojos pueden no ser el origen de muchas de estas enfermedades, son visibles para observadores externos, convirtiéndolos en un punto accesible de diagnóstico. Por ejemplo, vasos sanguíneos rotos en la esclerótica, podría indicar un trastorno de la coagulación de la sangre o una vitamina K deficiencia (Mariakakis et al, 2016).

1.1 Descripción del Problema

Existe una variedad de enfermedades de la retina, algunas de ellas son hereditarias, lo preocupante es que algunas afectan la retina en forma silenciosa. De no detectarse oportunamente y no tratarse adecuadamente, pueden provocar con el tiempo la ceguera. Como ya se ha indicado estas enfermedades son el glaucoma, la

retinopatía diabética, la retinopatía hipertensiva, la retinosis pigmentaria y la degeneración macular dependiente de la edad.

El diagnóstico precoz y su evaluación requieren un examen con lámpara de hendidura del iris y una evaluación gonioscópica del ángulo de filtración. El tratamiento incluye medicamentos, cirugía láser o cirugía convencional.

A pesar de que existen algunos sistemas comerciales especializados para el análisis de las retinas humanas, en su mayoría cuentan con un uso muy limitado debido a su alto costo de inversión y, por ende, un elevado precio por su uso, lo que conlleva un acceso reducido por parte de la población que tiene bajos y medios ingresos (Ríos et al., 2007).

La empresa WelchAllyn comercializa oftalmoscopio cuyos precios son diversos, van desde 151.25 a 1045.44 euros.

La empresa D-EYE Shop Online comercializa Smartphone con un dispositivo adicional que permite tener imágenes de fondo de ojo, cuyo precio se pueden encontrar entre \$109 a \$435

En nuestro país los problemas visuales representan la segunda causa de discapacidad a nivel nacional, se ha estimado, según el Instituto Nacional de Estadística e Información, en el 2016, el 2,9% de la población de 15 y más años de edad fue diagnosticada con diabetes mellitus, manteniéndose en el mismo valor que el 2015. Siendo la población femenina la más afectada (3,2%) respecto a la masculina (2,7%). Asimismo, por región natural, en el 2016, el mayor porcentaje de personas con diabetes fueron las residentes de Lima Metropolitana (4,6%) y en menor porcentaje las residentes de la Sierra (1,8%). Esta enfermedad es una de las principales causas de ceguera, insuficiencia renal, infarto de miocardio y accidente cerebrovascular.

La figura 1 la primera imagen muestra como una persona vería la imagen con una visión normal y la segunda muestra como una persona vería la imagen si tiene retinopatía diabética. (imagen tomada de NIH: National Eyes Institute, 2019)

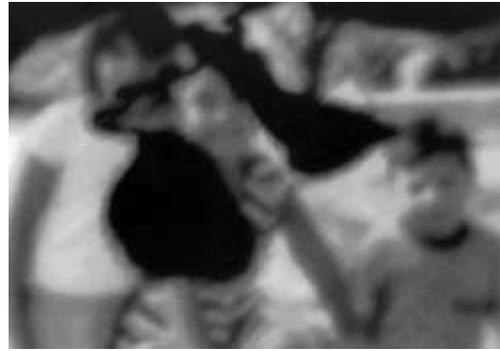


Figura 1 imagen vista por una persona sana y con retinopatía diabética

La retina es un tejido sensible a la luz ubicado en la capa interna del ojo y se puede visualizar con una cámara digital de fondo de ojo. Este tipo de cámara contiene un microscopio que es capaz de capturar la superficie interior del ojo. Si esta imagen se captura con una cámara de fondo de teléfono móvil, se debe tener cuidado porque podría capturarse una imagen inclinada o desalineada lo que causaría problemas para los algoritmos de localización existentes. Las imágenes inclinadas a menudo se encuentran en la cámara de fondo de mano, cuya orientación de disparo no es fija, como se ilustra en la figura 2 (Bodeetorn Sutcharit et al., 2018).



Figura 2. Una cámara de fondo de teléfono móvil

Pero se puede utilizar un teléfono inteligente y el accesorio óptico para mejorar la captura de la imagen, tal como se ilustra en la figura 3 (Prateek Prasanna et al., 2013).



Figura 3. Teléfono inteligente y el accesorio óptico.

Esta situación hace que se identifiquen las siguientes deficiencias en el área de oftalmología:

- a) Decisiones deficientes. - Debido a que no se tiene la información precisa del diagnóstico precoz en el momento que se requiere, esto origina que el diagnóstico precoz no sea confiable impidiendo que no se puedan tomar decisiones o que estas decisiones no sean las más acertadas.
- b) Duplicidad de esfuerzos. - Como no se tiene el apoyo de las tecnologías de la información y comunicación (TIC) se debe recurrir a otras instancias para que realicen el diagnóstico precoz, originando así una duplicidad de esfuerzo, pérdida de tiempo y costos adicionales.
- c) No existen mecanismos de control. - Como no existen mecanismos de control establecidos para verificar si el diagnóstico precoz es el adecuado, no se tiene la certeza si este diagnóstico precoz es confiable.
- d) Servicio inadecuado a los pacientes. - El no utilizar las TIC hace que los pacientes pierdan mucho tiempo para ser diagnosticados.

1.2 Formulación del Problema

1.2.1 Problema General

En este contexto es razonable formular la siguiente pregunta ¿Se puede mejorar la identificación de la retinopatía diabética y su tipo?

1.2.2 Problemas Específicos

Así mismo, también es razonable formular las siguientes preguntas más específicas con relación al problema, como se puede apreciar en la matriz de consistencia Anexo 1:

1. ¿Se puede detectar la retinopatía diabética y su tipo usando visión computacional?
2. ¿Se puede disminuir el costo del diagnóstico precoz en la identificación de la retinopatía diabética y su tipo usando visión computacional?
3. ¿Se puede disminuir el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética y su tipo usando visión computacional?

Considerando:

- Tener una base de datos de los casos de problemas de la visión
- Identificar la retinopatía diabética.
- Identificar las características de la retinopatía diabética.
- Apoyar el análisis del estado en que se encuentra la retinopatía diabética.

En la siguiente tabla 1 se muestra un resumen de esta problemática.

Tabla 1. Se muestra la problemática con sus causas y efectos.

Deficiente diagnóstico precoz de la retinopatía diabética de los pacientes.	
Causas	Efectos
No se tiene un medio fiable que permita determinar la retinopatía diabética.	No se sabe con certeza si tiene retinopatía diabética.
Muchos procedimientos para identificar la retinopatía diabética de acuerdo con sus características.	Demasiado tiempo para identificar la retinopatía diabética
Muchos equipos involucrados en los procedimientos para identificar la retinopatía diabética	Alto costo para identificar la retinopatía diabética de acuerdo con sus características

Elaboración: propia

1.3 Importancia y Justificación del Estudio (aporte, contribución)

A pesar del aumento alarmante de retinopatía diabética en todo el mundo, el rendimiento de los sistemas de evaluación, incluso en los países desarrollados, deja mucho que desear. La infraestructura existente para la detección de la retinopatía diabética incluye oftalmoscopia o fotografía estereoscópica de fondo de película en color. Con los sistemas tecnológicos avanzados, la telemedicina está desempeñando un papel importante en la captura de imágenes de fondo y en la transmisión de fotografías a oftalmólogos que se encuentran en otros lugares para su análisis y evaluación. Esta tendencia ha llevado a la adquisición y el despliegue generalizados de costosos sistemas de imágenes de fondo de ojo. Se está contratando a expertos para interpretar y calificar estas imágenes. Además, no existe un estándar universalmente aceptado para el análisis y clasificación de las imágenes de la retina. El resultado final aún depende de la experiencia manual del examinador. Con el crecimiento exponencial de este problema, la introducción de técnicas de bajo costo y efectivas en el tiempo es una necesidad global (Prateek Prasanna et al., 2013).

Con lo antes mencionado un examen de la retina puede durar entre 20 a 30 minutos (Lookafteryoureyes, 2018).

En nuestro país, en base a los registros del Ministerio de Salud (anexo 3), se puede evidenciar que desde el año 2014 al año 2017 se ha incrementado los casos de retinopatía diabética de 3976 casos a 5844 casos, es decir el incremento en tan solo tres años ha sido del 46.98%. Se observa además que la mayoría de los casos de retinopatía diabética se da en personas de 60 o más años, es una situación muy preocupante que amerita realizar un diagnóstico precoz a temprana edad para evitar que estos casos sigan aumentando.

Existen recomendaciones que el examen de retina se realice por lo menos cada año y este puede durar aproximadamente una hora (Finley, 2016).

El área de interés son los problemas de la visión que están relacionados con la retinopatía diabética, es decir la delimitación del problema está enfocado en identificar la retinopatía diabética, a través de la visión computacional, que puede

utilizar una o varias bases de datos disponibles públicamente como: drive, stare, diarectdb0, diarectdb1, mesidor, e_ophta_MA y Kaggle.

Se puede decir que los oftalmólogos tienen mucha dificultad para realizar un diagnóstico precoz en la identificación de la retinopatía diabética,

1.4 Delimitación del estudio

En la actualidad hay muchas personas con problemas de retinopatía diabética, esto se debe a muchos factores entre ellos: el medio ambiente, la alimentación, la higiene, etc. Pero no es posible tener todos los casos que se puedan presentar en relación con la retinopatía diabética, por esta razón se está considerando la base de datos Kaggle, que contiene imágenes seleccionadas por expertos en el campo de la retinopatía diabética.

Otras de las razones por las cuales no se puede tener las imágenes de fondo de ojos es porque los pacientes no dan su consentimiento para que estas sean utilizadas sin su permiso.

Espacial. – Las imágenes que se están considerando en la investigación han sido obtenidos en base de datos públicas (imágenes de fondo de ojos). También se está considerando al Centro Médico Naval, quienes pueden utilizar el estudio realizado y así tener una alternativa de diagnóstico precoz de la retinopatía diabética en sus pacientes.

Temporal. - El estudio está considerando el periodo de 2019 - 2020

Teórica. – La investigación propone una forma diferente de realizar el diagnóstico precoz para identificar si una persona tiene retinopatía diabética.

1.5 Objetivos de la Investigación:

1.5.1 Objetivo general

Mejorar el diagnóstico precoz de la retinopatía diabética utilizando visión computacional.

1.5.2 Objetivos específicos

Obj1: Detección de la retinopatía diabética.

Obj2: Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética.

Obj3: Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética

Estos objetivos también se muestran en la matriz de consistencia Anexo 1.

Capítulo II: MARCO TEÓRICO

2. Marco teórico

En la actualidad existen condiciones que incrementan la retinopatía diabética, por ejemplo, no se pone en práctica la prevención, es decir las personas generalmente van al oftalmólogo cuando dicha anomalía está avanzada, aunado a esto está la alimentación que muchas veces no ayuda a fortalecer los nervios ópticos a través de los antioxidantes que debe ser parte de toda dieta alimenticia.

La tecnología está apoyando las diferentes disciplinas que realiza el ser humano, lo que hace que se dé una transformación en la forma que se realizan las tareas dentro y fuera de toda empresa. Las investigaciones que se realizan en la electrónica, telecomunicaciones, medicina, la genética hacen pensar que el proceso para identificar alguna enfermedad debe ser con el apoyo de esta tecnología.

Esta situación plantea nuevos retos donde cada sociedad debe contribuir para adoptar los avances tecnológicos y nuevos conocimiento en la prevención de enfermedades, como la retinopatía diabética, que pone en peligro la salud de los habitantes a tal punto que puede hacer que pierdan la visión.

Se sabe que la retinopatía diabética tiene más incidencia en los países menos desarrollados y los estudios demuestran que cada año existe un incremento significativo en personas con esta enfermedad

2.1 Marco histórico

Hoy en día podemos observar que hay varios estudios orientados al diagnóstico de la retinopatía diabética ya sea utilizando procesos manuales o automatizados. Con el avance de las tecnologías de la información y comunicación se tiene equipos de alta tecnología que pueden realizar un diagnóstico al fondo del ojo en poco tiempo y con una alta precisión en cuanto a identificar a la retinopatía diabética y su tipo. Esto ha permitido que profesionales de la ciencia de la computación realicen investigaciones vinculadas al campo de la medicina, precisamente para desarrollar sistemas que apoyen la labor, por ejemplo, al oftalmólogo.

Se debe promover entre las personas que periódicamente se realicen un análisis para descartar que tengan la enfermedad de la retinopatía diabética, de esta manera el país entero tendrá la seguridad que no lidiará en el futuro con este problema y estará aumentado más personas sanas para el bienestar de todos.

2.2 Investigaciones relacionadas con el tema

Existen diversos trabajos orientados al diagnóstico precoz de la retinopatía diabética, por ejemplo:

- Automatic detection of microaneurysms in colour fundus images for diabetic retinopathy screening (junio, 2015), Sarni Suhaila Rahim, Chrisina Jayne, Vasile Palade, James Shuttleworth.

Este trabajo presenta una estrategia automatizada que consiste en una adquisición, selección y clasificación automáticas de las imágenes del fondo de color de la retinopatía diabética, para ayudar en la detección y el tratamiento de la retinopatía diabética. Hace una comparación entre varios métodos existentes y llega a la conclusión que el método de ecualización de histograma borroso que es aplicado en el preprocesamiento de las imágenes del fondo de ojo de la retinopatía diabética y proporcionó mejores resultados para detectar los microaneurismas.

- Exudate and Blood Vessel Feature Extraction in Diabetic Retinopathy Patients using Morphology Operation (diciembre, 2016), Siswo Wardoyo, Anggoro Suryo Pramudyo, Erika Diana Rizanti, Imamul Muttakin.

En este trabajo de investigación se reconoce que la retinopatía diabética es una enfermedad con síntomas observables a través de la aparición de exudados y nuevos vasos sanguíneos, por lo que propone la detección automática de características que ayudan al médico a procesar la imagen de la retina para analizar la enfermedad de la retinopatía diabética.

- Automatic Detection of Microaneurysms in Retinal Images (diciembre, 2017), Sangita Bharkad.

Como la detección de los microaneurismas (MA) en la etapa inicial de la retinopatía diabética puede prevenir la pérdida de visión. Este trabajo se propone un nuevo enfoque para encontrar los MA en la imagen del fondo de ojo. Proponen un método que sigue tres pasos para la detección de MA. La mejora del contraste local de la imagen del fondo de ojo y la extracción de los vasos sanguíneos se completan en los primeros dos pasos. En el último paso, los MA se detectan en función de las características de tamaño y forma. El método propuesto se prueba en la base de datos diaretdb1. El método propuesto alcanzó una sensibilidad del 87.5% para reconocer MA en imágenes de fondo de ojo.

2.3 Estructura teórica y científica que sustenta el estudio (teorías, modelos)

Inteligencia artificial

La inteligencia artificial (IA) ha cambiado la forma en que vivimos y la forma en que trabajamos, a tal punto que ha pasado a ser una estrategia para el desarrollo de las industrias, incorporando métodos y técnicas que permiten un rápido desarrollo rápido de los objetivos propuestos. Algunos la consideran como la “cuarta revolución industrial” (Zhou Shao et al., 2020), porque ha, traído revoluciones dramáticas a todas las organizaciones de la sociedad incluyendo a la misma sociedad humana, es decir, está en todos los campos de la investigación y su aplicación, porque la inteligencia artificial es una amplia que se puede aplicar a muchos campos de la investigación.

Existe un interés muy grande que la inteligencia artificial y el aprendizaje automático apoye la labor de los médicos, sin que reemplace la labor de los médicos debe más bien crearse una relación médico-paciente que permita a los médicos mejorar la toma de decisiones relacionadas al tratamiento que se le debe dar al paciente (Arisa Ema et al., 2020). Esto se puede lograr si se realizan trabajos coordinados entre todas las partes interesadas como médicos, pacientes, investigadores, desarrolladores de aplicaciones, dispositivos de inteligencia artificial.

Nuestro país debe contribuir estableciendo marcos regulatorios y relaciones médico-paciente.

Aprendizaje automático (machine learning-ML)

El aprendizaje automático está siendo más utilizado en estos días, involucra diseñadores y científicos que trabajan juntos generando una serie de pasos en un proceso para conseguir formas optimizadas, configuraciones espaciales y objetos de mayor rendimiento. Se puede decir que el aprendizaje automático se puede aplicar en:

- **Herramientas analíticas**, donde los diseñadores usan técnicas de ML para simular y monitorear posibles escenarios de diseño. Un ejemplo reciente de este enfoque es el proyecto de la Estación AI de MIT SenseAble City Lab que analizó las señales de Wi-Fi para comprender cómo se mueven los pasajeros a través de dos estaciones de tren en París.
- **Herramientas de diseño** que se han desarrollado para ayudar a los diseñadores en sus proyectos e investigación, principalmente en plataformas abiertas.
- **Herramientas de gestión e información** y puede considerarse como una versión extendida de los sistemas de modelado de información de edificios. El objetivo de este proyecto es fomentar nuevas formas de administrar la infraestructura digital pública de planificación a través de bases de datos cada vez más interconectadas que utilizan los diferentes actores involucrados en el proceso de planificación, y servicios más automatizados y optimizados para los usuarios finales (Carta Silvio, 2020).

Los avances tecnológicos han permitido que el aprendizaje automático este en todas las aplicaciones basadas en datos de alto valor. Tradicionalmente los sistemas de gestión de bases de datos han sido el centro de desarrollo de cualquier sistema basado en base de datos, pero ahora se está buscando como mejorar estos sistemas que permitan darle soporte a las nuevas aplicaciones desarrolladas que incorporan el aprendizaje automático.

Pero las aplicaciones de aprendizaje automático exitosas requieren un proceso iterativo para crear modelos que brinden el rendimiento deseado y la experiencia del usuario, como se muestra en la figura 4, en ella se puede apreciar una descripción general de un proceso típico de aprendizaje automático, que implica tanto la iteración del modelo como la iteración de datos (Fred Hohman et al., 2020).

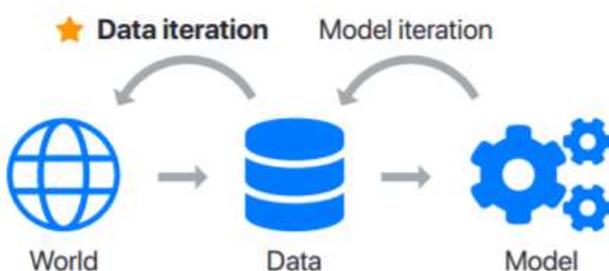


Figura 4. Descripción general de un proceso típico de aprendizaje automático.

Redes neuronales artificiales

Las redes neuronales artificiales tratan de simular el comportamiento del cerebro humano, es decir, se trata de crear modelos artificiales que nos ayuden a dar solución a problemas complejos y difíciles en diferentes campos de investigación, para ello estas redes neuronales artificiales utilizan diversas técnicas de algoritmos. Estas redes son una de las principales técnicas en inteligencia computacional que a través de sus modelos artificiales de aprendizaje demuestran propiedades útiles la adaptabilidad, la capacidad de aprendizaje y la capacidad de generalización. Existen diversos tipos de redes neuronales artificiales pero las más utilizadas son la red neuronal multicapa, en ella es importante definir los pesos apropiados para minimizar el error entre la salida real y la salida deseada (Seyed Jalaeddin Mousavirad et al., 2020). Actualmente hay una necesidad de reconocimiento automático, descripción, clasificación y agrupación de patrones relevantes en diversas disciplinas como la inteligencia artificial y la visión por computadora, se ha avanzado bastante en este aspecto más aun en el campo de la clasificación visual, a pesar de que

se requiere un gran volumen de muestras para poder lograr resultados aceptables.

Como se ha mencionado las redes neuronales multicapa son uno de los tipos más utilizados de las redes neuronales artificiales. Están constituidas de nodos (neuronas) que están organizados en tres tipos de capas: entrada, salida y capas ocultas. Si bien una sola capa oculta es generalmente suficiente para la aproximación de funciones, no existe una regla general con respecto al número de capas ocultas. La figura 5 muestra su estructura, en ella se puede apreciar los valores de entrada (x) se pasan, en forma ponderada, a través de la red a los nodos de salida (o). Cada conexión tiene un peso (w) que indica la fuerza de la conexión, mientras que cada nodo (b) (excepto los nodos en la capa de entrada) tiene un sesgo (s). Al incorporarlos, se emplea una función de activación para controlar la salida de cada nodo (Seyed Jalaeddin Mousavirad et al., 2020)

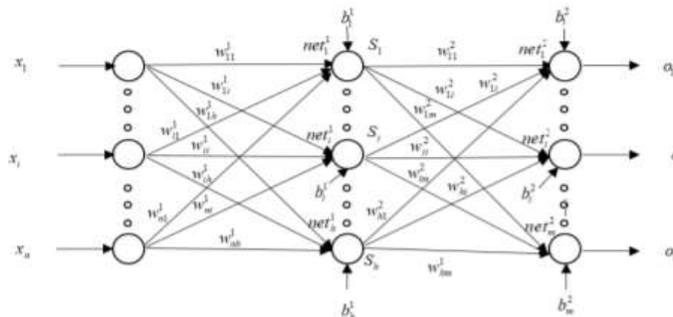


Figura 5. Estructura general de una red neuronal multicapa.

Redes neuronales convolucionales

Las redes neuronales convolucionales son un tipo de redes neuronales artificiales que tiene una amplia aplicación en el campo de la visión computacional, reconocimiento de voz, entre otras áreas más. Se puede decir que actualmente han evolucionado y como ejemplo de ello podemos ver que se utilizan en redes modernas no lineales como ResNet, GoogleNet y otras más, esto ha sido posible utilizando algoritmos muy eficientes como el

algoritmo FFT (selección TensorFlow), lo que mejora el paralelismo en una sola GPU. Estos GPU son la plataforma elegida para entrenar redes neuronales. Pero entrenar red neuronal convolucional es un proceso que consume mucho tiempo incluso en las GPU debido a la gran cantidad de parámetros que deben aprenderse. La figura 6 muestra la estructura de una red lineal y la estructura de una red no lineal (Behnam Pourghassemi et al., 2020)

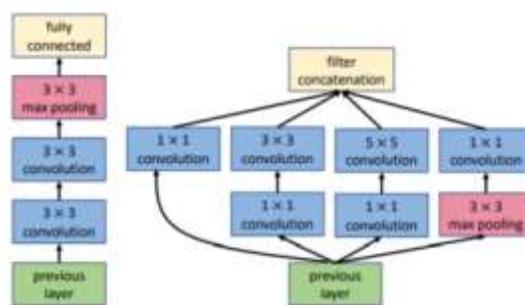


Figura 6. Estructura de una red lineal y estructura de una red no lineal.

Procedimiento de aprendizaje

El procedimiento de aprendizaje de las redes neuronales convolucionales es bastante complejo por lo general se entrenan en un conjunto de imágenes grande y diverso en hardware potente durante días o incluso semanas, lo que las convierte en una herramienta poderosa, pero se puede utilizar el aprendizaje de transferencia para disminuir el tiempo de entrenamiento, mientras se usan menos recursos. Toma los pesos de una red neuronal convolucional entrenado (con y capas ocultas) que ya ha sido entrenado en un conjunto de imágenes comparable y ve las primeras n capas ocultas como un cuadro negro (por lo tanto, $n < y$). Estas n capas ocultas se congelan y los pesos de las capas finales $y - n$ se entrenan utilizando el nuevo conjunto de imágenes (generalmente las capas completamente conectadas). La suposición aquí es que las primeras n capas ocultas extraen características (como bordes) que son comparables entre los conjuntos de imágenes. Las capas finales $y - n$ combinan estas características básicas para detectar características más complejas (Jeroen Klein Brinke et al., 2020)

Por ejemplo, podemos apreciar en la figura 7 una capa de entrada (IL) de tamaño 64×64 , que registra la imagen en escala de grises de un parche de imagen; dos etapas en cascada de coincidencia de características alternativas (S1, S2) y agrupación (C1, C2) de capas con 20 canales de características cada una, y una capa de clasificación (CL) con seis celdas de salida.

La primera capa de coincidencia (S1) consta de veinte mapas de 60×60 , la primera capa de agrupación (C1) de veinte mapas de 20×20 , la segunda capa de coincidencia (S2) de veinte mapas de 16×16 y la segunda capa de agrupación (C2) de veinte mapas 6×6 . Cada mapa en S1 se forma convolucionando IL con uno de los veinte núcleos 5×5 , y cada mapa en S2 filtra las entradas de todos los canales de características en C1. Ambas capas de agrupación (C1, C2) submuestran sus capas de coincidencia de entrada calculando valores medios sobre 3×3 ventanas espaciales no superpuestas en cada uno de los 20 mapas. Cada mapa en las capas de coincidencia de características S1 y S2 y cada celda en la capa de clasificación también tenían términos de sesgo, y la función de activación logística ($1 / (1 + e^{-x})$) se usó en las salidas de S1, S2 y CL para suprimir ruido y también colocar límites en las actividades de celda correspondientes ($[0, 1]$) (Praveen K. Pilly et al., 2020)

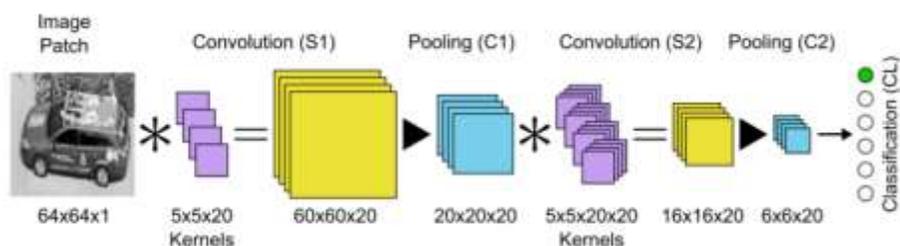


Figura 7. Diagrama de bloques de un sistema ilustrativo de reconocimiento basado en la red neuronal de convolución de cinco capas, desde el parche de imagen hasta la capa de clasificación.

Visión computacional

La visión es el sentido de la vista, considerado el más complejo de todos los sentidos, a pesar del conocimiento limitado sobre el funcionamiento interno del cerebro.

La visión por computadora es una disciplina cuya primera base teórica se formuló en la década de 1960, es sobre todo una ciencia aplicada y, por lo tanto, la usabilidad de las técnicas propuestas para resolver problemas visuales es de gran importancia. Los requisitos típicos de hardware y software incluyen cámaras de video fijas de alta resolución, cámaras estereoscópicas, así como la computadora host utilizada en sistemas típicos de visión por computadora y fotogramétricos. El reconocimiento automático, la descripción, la clasificación y la agrupación de patrones son tareas relevantes en una variedad de disciplinas como la visión por computadora. Independientemente de más de 50 años de investigación, el diseño de un enfoque de reconocimiento de patrones de propósito general sigue siendo un objetivo difícil de alcanzar. La capacidad de generalizar conceptos visuales a partir de pequeñas cantidades de imágenes para el reconocimiento de patrones es una característica muy deseada en los sistemas modernos de visión por computadora (Vargas Camilo et al., 2020)

Modelo de desarrollo

Para poder elaborar un proyecto es necesario tener un modelo a seguir, en él se encontrará el marco de referencia para realizar el trabajo propuesto y así lograr el objetivo trazado. Existen varios modelos de desarrollo entre ellos se puede mencionar uno que involucra cuatro módulos (Libralao, G. L. et al, n.d.).

- Módulo de adquisición de imágenes. La adquisición de las imágenes oftálmicas mediante la base de datos Kaggle.
- Módulo de preprocesamiento de imágenes. Las imágenes oftálmicas se generan en un formato que no permite su uso directo por técnicas de machine learning. Primero se normalizan la imagen, luego la imagen se filtra para eliminar el ruido que puede afectar el proceso de extracción de características.
- Módulo de extracción de características. Este módulo tiene como objetivo la extracción de la característica principal de una imagen para reducir la cantidad de imágenes de entrada para el módulo de análisis.

- Módulo de análisis. Este módulo analiza los patrones proporcionados por el módulo de extracción de características.

La figura 8 muestra las imágenes retínicas anormales y normales, estas imágenes luego se preprocesan. (Amol Prataprao Bhatkar et al., 2016)

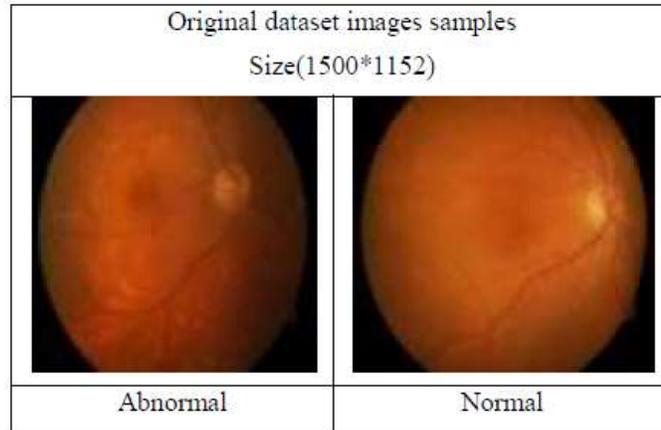


Figura 8. Fundus retinal imágenes originales.

La figura 9 muestra las imágenes preprocesadas por tamaño y en escala de grises antes de la extracción de la característica. (Amol Prataprao Bhatkar et al., 2016)

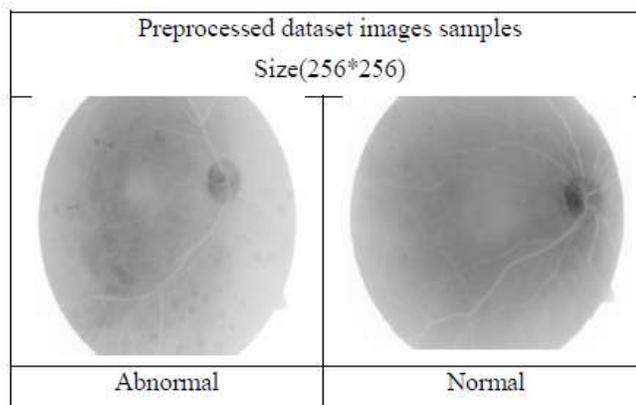


Figura 9. Imágenes retínicas pre procesadas.

2.4 Definición de términos básicos

En la figura 10 se presenta una ilustración de algunos componentes del ojo, que incluyen: iris, pupila, lente, córnea, cámara posterior, coroides, esclera, retina, mácula, fovea, disco óptico, nervio óptico y vasos retinianos. (Anuradha M. Kudatarkar et al., 2016-17)

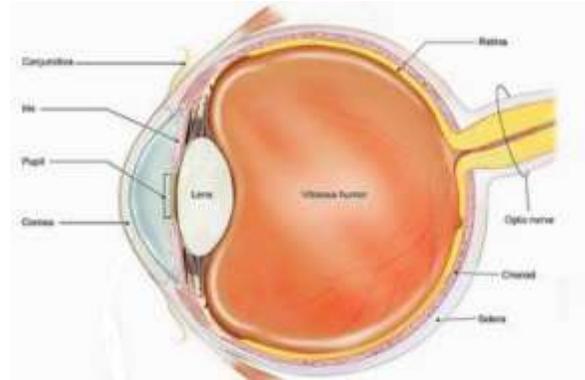


Figura 10. Componentes del ojo.

Convolución

Es el proceso central de una red neuronal convolucional, consiste en considerar un grupo de píxeles cercanos de una imagen de entrada a la red, e ir realizando el producto escalar con una matriz. Este producto se realiza de izquierda a derecha y de arriba abajo, el propósito es obtener una matriz de salida que constituya la nueva capa de neuronas ocultas.

Filtrar una imagen

Para filtrar una imagen se pueden utilizar diversos métodos con el propósito de resaltar o suprimir información que se encuentra en la imagen, en algunos casos para realizar este proceso se puede utilizar la transformada de Fourier.

Gonioscopia

Es un examen de la vista para observar la parte frontal del ojo (cámara anterior) entre la córnea y el iris. La gonioscopia es un examen indoloro para

ver si la zona de donde sale el líquido del ojo (llamada ángulo de drenaje) se encuentra abierta o cerrada.

Inteligencia artificial

“El estudio de las computadoras que permiten percibir, razonar y actuar.”
(Winston, 1992)

Desde 1950 los avances en la Inteligencia Artificial se orientaron básicamente a identificar reglas del pensamiento, pero esto es bastante complicado, por esta razón los científicos han considerado el campo de las probabilidades, identificando patrones estadísticos que le permitan a los computadores aprender a partir de una gran base de datos.

Imagen de fondo de ojo

Muestra el revestimiento interno del ojo formado por la retina sensorial, el epitelio pigmentario de la retina, la membrana de Bruch y las coroides. Si esta imagen se pone en blanco y negro se puede estudiar partes muy específicas de la capa retiniana.

Kernel

En las redes neuronales convolucionales se considera un kernel a una matriz pequeña por ejemplo de 3x3 píxeles, que se utiliza para realizar el proceso de convolución.

Mácula

Es un área muy pequeña en el centro de la retina. La mácula es el área responsable por la visión detallada, permitiéndonos leer, coser o reconocer una cara.

Max polling

Es una técnica que permite a una red neuronal convolucional seguir reconociendo la imagen a pesar de que se han realizado algunos cambios en ella,

estos cambios van a permitir almacenar la información más importante que permitan detectar las características que se desean.

Oftalmoscopio

Es un instrumento que permite examinar la parte interna del ojo. Existen dos tipos: directo e indirecto. El oftalmoscopio directo permite examinar una zona más reducida de la retina de una sola vez. El oftalmoscopio indirecto permite examinar una zona de mayor tamaño de la retina de una sola vez, pero con un aumento más reducido.

Píxeles y neuronas

Toda imagen está conformada por píxeles que es la entrada en una red neuronal, de tal manera que, si la imagen tiene 32×32 píxeles de alto y de ancho, entonces se necesita utilizar $32 \times 32 = 1024$ neuronas, siempre que la imagen sea en escala de gris, pero si la imagen es de color se necesitaría 3 canales (rojo, verde, azul), lo que daría un total de $32 \times 32 \times 3 = 3072$ neuronas.

Retina

Es una capa fina de tejido sensible a la luz que cubre la parte posterior del ojo. Los rayos de luz se enfocan en la retina, donde son transmitidos al cerebro e interpretados como imágenes. La parte alrededor de la retina, llamada retina periférica, es responsable por la visión lateral o periférica.

TensorFlow.

Es una biblioteca de código abierto, desarrollado por Google, que está disponible para todas aquellas personas que deseen desarrollar trabajos relacionados con el aprendizaje automático, a través de la construcción y entrenamiento de redes neuronales.

vCPU.

En la actualidad los proveedores de servidores de la nube están utilizando este término para indicar la potencia de sus servidores.

Visión computacional.

Permite que la computadora u otra máquina este capacitada para ver, es decir que a través de dispositivos pueda capturar imágenes o videos e interpretar su contenido.

2.5 Fundamentos teóricos y/o mapa conceptual (de la teoría que sustenta la hipótesis).

Los fundamentos teóricos ayudan a comprender las variables que han sido identificadas en el proyecto.

Variable independiente: Visión computacional

Variable dependiente: Diagnóstico precoz de la retinopatía diabética y su tipo

2.5.1 Visión computacional

La visión computacional es la construcción de descripciones explícitas y significativas de objetos físicos a partir de imágenes. La comprensión de la imagen es muy diferente del procesamiento de la imagen, que estudia las transformaciones de la imagen, no la creación explícita de la inscripción. Las descripciones son un requisito previo para reconocer, visualizar y pensar acerca de los objetos.

El reto de la visión por ordenador es uno de los explícitos. ¿Exactamente qué información sobre las escenas se puede extraer de una imagen usando solo suposiciones muy básicas sobre física y óptica? Explícitamente, ¿qué cálculos se deben realizar? Entonces, ¿en qué etapa debe ser dependiente del dominio, el conocimiento previo sobre el mundo debe incorporarse al proceso de comprensión? ¿Cómo se representan y utilizan los modelos y conocimientos mundiales?

La visión computacional es un campo relativamente nuevo y de rápido crecimiento. Los primeros experimentos se llevaron a cabo a fines de la década de 1950, y muchos de los Conceptos esenciales se han desarrollado durante los últimos cinco años. Con este rápido crecimiento, las ideas cruciales han surgido en áreas dispares como la inteligencia artificial, la

psicología, los gráficos por computadora y el procesamiento de imágenes. (Ballard et al., 1982)

El objetivo de la visión por computadora es extraer información útil de las imágenes. Esto ha demostrado ser una tarea sorprendentemente desafiante; ha ocupado miles de mentes inteligentes y creativas en las últimas cuatro décadas y, a pesar de esto, todavía estamos lejos de poder construir una "máquina de visión" de propósito general (Prince, 2012).

En base a lo antes mencionado, en la figura 11 se muestra el mapa conceptual considerando como variable independiente: visión computacional.

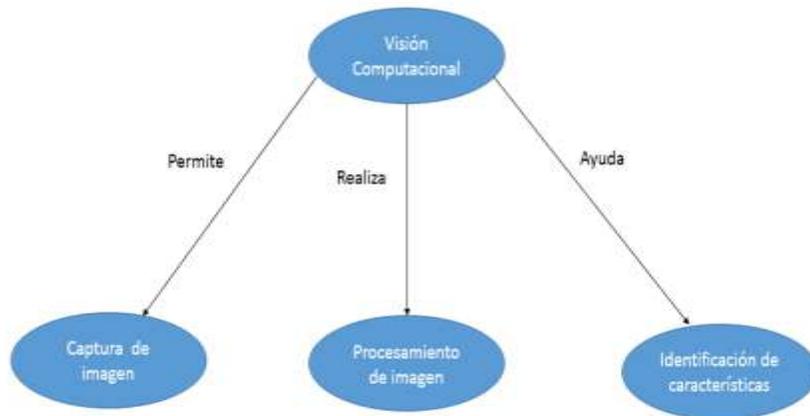


Figura 11. Mapa conceptual de la variable independiente Visión computacional.

2.5.2 Diagnóstico precoz de la retinopatía diabética y su tipo

Se presenta cuando hay cambios en los vasos sanguíneos en la retina. Existen dos tipos de retinopatía diabética:

- De fondo o retinopatía diabética no proliferativa (RDNP)

La retinopatía diabética no proliferativa (NPDR) es el conjunto de cambios tempranos que tienen lugar en la retina. Se divide en 3 categorías en leves, moderadas y graves. Cambios iniciales cuando comienzan a aparecer los microaneurismas (MA). Luego es seguido por hemorragias. Finalmente, la aparición de manchas de algodón y

exudados duros lo clasifica en NPDR grave. La etapa de neovascularización (NV) cuando comienzan a aparecer nuevos vasos sanguíneos (para compensar la reducción del suministro de sangre y la nutrición a la retina) finalmente califica para la retinopatía diabética proliferativa (Neera Singh et al., 2010).

La RDNP puede causar cambios en los ojos, incluyendo:

- Microaneurismas: Unas pequeñas protuberancias en los vasos sanguíneos de la retina que con frecuencia dejan escapar líquidos.
- Hemorragias de la retina: Unas pequeñas manchas de sangre que entran a la retina.
- Exudados duros: Es la inflamación o engrosamiento de la mácula a causa de escapes de líquido de los vasos sanguíneos de la retina. La mácula no funciona correctamente cuando está inflamada. El edema macular es la causa más común de pérdida de la visión durante la diabetes.
- Exudados macular: Es la inflamación o engrosamiento de la mácula a causa de escapes de líquido de los vasos sanguíneos de la retina. La mácula no funciona correctamente cuando está inflamada. El edema macular es la causa más común de pérdida de la visión durante la diabetes.
- Isquemia macular: Los pequeños vasos sanguíneos (capilares) se cierran o se tapan. Su visión se torna borrosa ya que la mácula no recibe suficiente sangre para funcionar correctamente.

Muchas personas con diabetes tienen RDNP ligera, lo que por lo general no afecta la visión. Sin embargo, si su visión se ve afectada, es como resultado de un edema macular y una isquemia macular.

- Retinopatía diabética proliferativa (RDP)
Sucede principalmente cuando muchos de los vasos sanguíneos de la retina se tapan, impidiendo un flujo suficiente de la sangre. En un

intento de suministrar sangre a la zona donde los vasos originales se han tapado, la retina responde creando nuevos vasos sanguíneos. Este proceso se llama neovascularización. Sin embargo, los nuevos vasos sanguíneos también son anormales y no proporcionan a la retina con el flujo sanguíneo adecuado. A menudo, los nuevos vasos van acompañados por tejidos cicatrizados que pueden hacer que la retina se arrugue o se desprenda.

La RDP puede causar una pérdida de la visión más severa que la RDNP, ya que puede afectar tanto la visión central como la periférica. La RDP afecta la visión de las siguientes maneras:

- ✓ Hemorragia vítrea: Los nuevos y delicados vasos sanguíneos sangran dentro del vítreo (la sustancia gelatinosa en el centro del ojo), previniendo que los rayos de luz lleguen a la retina. Si la hemorragia es pequeña, es posible que usted vea algunas nuevas manchas oscuras y flotantes. Una hemorragia muy grande puede bloquear la visión, permitiéndole sólo ver la diferencia entre claro y oscuro. Una hemorragia vítrea por sí sola no causa una pérdida de visión permanente. Toda vez que la sangre desaparece, la visión puede volver a su estado anterior, a menos que la mácula se haya dañado.
- ✓ Desprendimiento de la retina por tracción: Cuando el tejido de una cicatriz producida por una neovascularización se encoge, la retina se arruga y puede desprenderse de su posición normal. Estas arrugas maculares pueden distorsionar la visión. Pérdida de la visión más grave pueden ocurrir si la mácula o áreas grandes de la retina se desprenden.
- ✓ Glaucoma neovascular: Si una serie de vasos de la retina se cierran, una neovascularización en el iris (la parte coloreada del ojo) puede ocurrir. Cuando esta condición existe, los nuevos vasos sanguíneos pueden bloquear el flujo normal de

líquido en el ojo. La presión en el ojo aumenta, lo que presenta una condición particularmente grave que causa daños al nervio óptico

En la figura 12 se puede apreciar el mapa conceptual de la variable dependiente diagnóstico precoz.

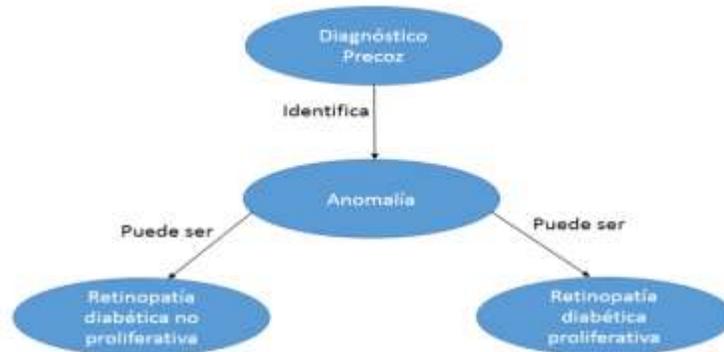


Figura 12. Mapa conceptual de la variable dependiente diagnóstico precoz

2.6 Hipótesis:

2.6.1 Hipótesis general

El diagnóstico precoz de la retinopatía diabética se mejora con la visión computacional.

2.6.2 Hipótesis específicas

Hipótesis específica 1:

Se mejora la identificación de la retinopatía diabética usando visión computacional.

Hipótesis específica 2:

Se disminuye el costo del diagnóstico precoz en la identificación de la retinopatía diabética, utilizando equipos de TIC, como por ejemplo Smartphone.

Hipótesis específica 3:

Se disminuye el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética, utilizando equipos de TIC y algoritmos que permitan una identificación de la retinopatía diabética.

2.7 Variables (definición y operacionalización de variables: Dimensiones e indicadores)

Tabla 2 Variable independiente.

Denominación	Visión computacional	
Tipo	Independiente	Indicadores
Dimensión	• Tratamiento de la imagen de fondo de ojo	• Precisión. • Tiempo de respuesta.
	• Accesibilidad económica	• Cantidad de dinero que se gasta en la atención.

Elaboración: Propia

Tabla 3. Variable dependiente.

Denominación	Diagnóstico precoz	
Tipo	Dependiente	Indicadores
Dimensión	• Anomalía	• Retinopatía diabética

Elaboración: Propia

Matriz de operacionalización de las variables independiente y dependiente

Tabla 4. Matriz de operacionalización

Objetivo general: Mejorar el diagnóstico precoz de la retinopatía diabética y su tipo utilizando visión computacional				
Objetivos específicos	Variables	Dimensión	Indicadores	Ítems
Detección de la retinopatía diabética usando visión computacional.	Visión computacional	Tratamiento de la imagen de fondo de ojo	Precisión.	¿Cuáles son los métodos para el tratamiento de las imágenes de fondo de ojo?
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?
Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Visión computacional	Accesibilidad económica	Cantidad de dinero que se gasta en la atención	Cantidad de soles
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?
Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Visión computacional	Tratamiento de la imagen de fondo de ojo	Tiempo de respuesta	Cantidad de segundos
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?

Elaboración propia.

Capítulo III: MARCO METODOLÓGICO

3. Marco metodológico

3.1 Tipo, método y diseño de la investigación

3.1.1 Tipo

Posteriormente al haber revisado la literatura existente sobre el tema, es momento de visualizar el alcance del estudio que se efectuará. Existen diversos tipos de investigación, estos son:

Exploratorios: El objetivo primordial de estos estudios es examinar un tema o problema de investigación poco estudiado o que nunca ha sido abordado antes.

Descriptivos: Estos recolectan datos del problema a investigar, los miden y evalúan para describir lo que se investiga.

Correlacionales: Pretenden medir el grado de relación entre dos o más variables.

Explicativos: Su objetivo es responder a las causas de los eventos, sucesos y fenómenos físicos o sociales.

Ninguno es más importante que otro, todo depende del enfoque que se maneje. En nuestro caso la investigación será de naturaleza exploratoria porque se está considerando un tema poco estudiado con relación al uso de tecnología como la visión computacional y además es de carácter descriptiva porque utilizando datos relacionados a la investigación se hará un análisis para poder dar una descripción de lo que se estamos investigando.

Los estudios exploratorios se realizan “cuando la revisión de la literatura reveló que únicamente hay guías no investigadas e ideas vagamente relacionadas con el problema de estudio, o bien, si deseamos indagar sobre temas y áreas desde nuevas perspectivas” (Hernández, 2014, p. 91).

Los estudios descriptivos “trabajan sobre realidades de hecho, y su característica fundamental es la de presentarnos una interpretación correcta” (Tamayo, 2012, p. 52).

3.1.2 Método

Como nuestra investigación tiene un enfoque cuantitativo se ha considerado el método deductivo en el tratamiento de las imágenes.

El enfoque cuantitativo “el investigador utiliza sus diseños para analizar la certeza de las hipótesis formuladas en un contexto en particular o para aportar evidencias respecto de los lineamientos de la investigación (si es que no se tienen hipótesis)” (Hernández, 2014, p. 128).

El método deductivo “Dentro del enfoque deductivo-cuantitativo, las hipótesis se contrastan con la realidad para aceptarse o rechazarse en un contexto determinado” (Hernández, 2014, p. 122).

También se sabe que existen diversos métodos para la detección de la retinopatía diabética y algunos de ellos son:

La diabetes mellitus tipo 1 (DM1), también llamada diabetes juvenil, es una enfermedad crónica que surge cuando el páncreas se encuentra enfermo y produce poca o ninguna insulina.

La insulina es una hormona que actúa permitiendo la entrada de glucosa (azúcar) dentro de las células, donde ellas son utilizadas como combustible para generar energía para el cuerpo. La Figura 13 muestra el procedimiento para la evaluación de pacientes que tienen diabetes tipo 1 (imagen tomada de CENETEC: Instituto Mexicano del Seguro Social, 2014).

Esquema de evaluación de retina para diabéticos tipo 1.

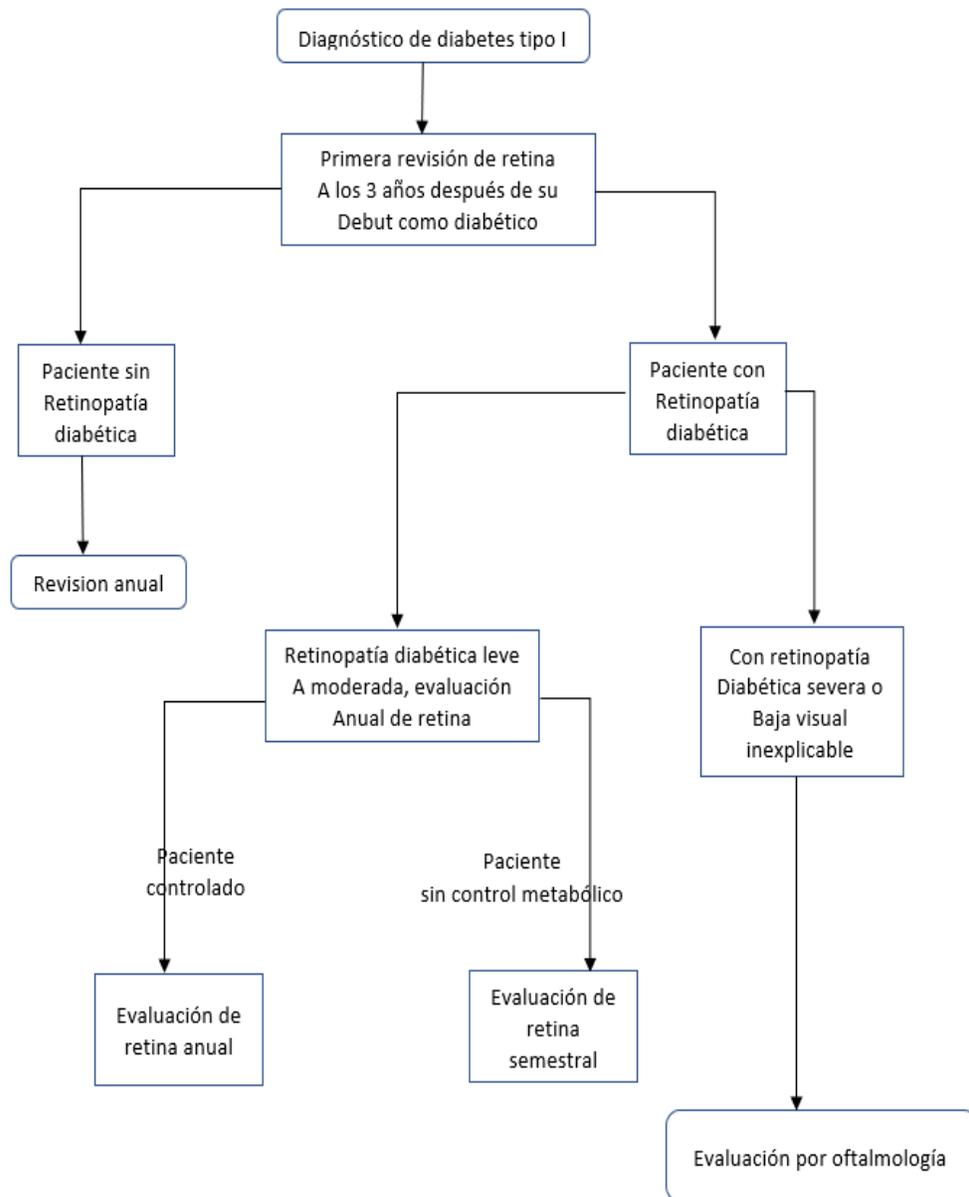


Figura 13. Procedimiento de evaluación para pacientes diabéticos tipo 1.

La diabetes mellitus tipo 2 (DM2) es un tipo de diabetes que ocurre por una acción deficiente de la insulina en la circulación sanguínea. El páncreas produce insulina, pero los tejidos no reconocen su presencia, impidiendo que la glucosa pueda entrar dentro de las células, un proceso conocido como

resistencia a la insulina. ocurre principalmente en adultos que son obesos, sedentarios y con historial familiar positivo. La Figura 14 muestra el procedimiento para la evaluación de pacientes que tienen diabetes tipo 2 (imagen tomada de CENETEC: Instituto Mexicano del Seguro Social, 2014).

Esquema de evaluación de retina para diabéticos tipo 2.

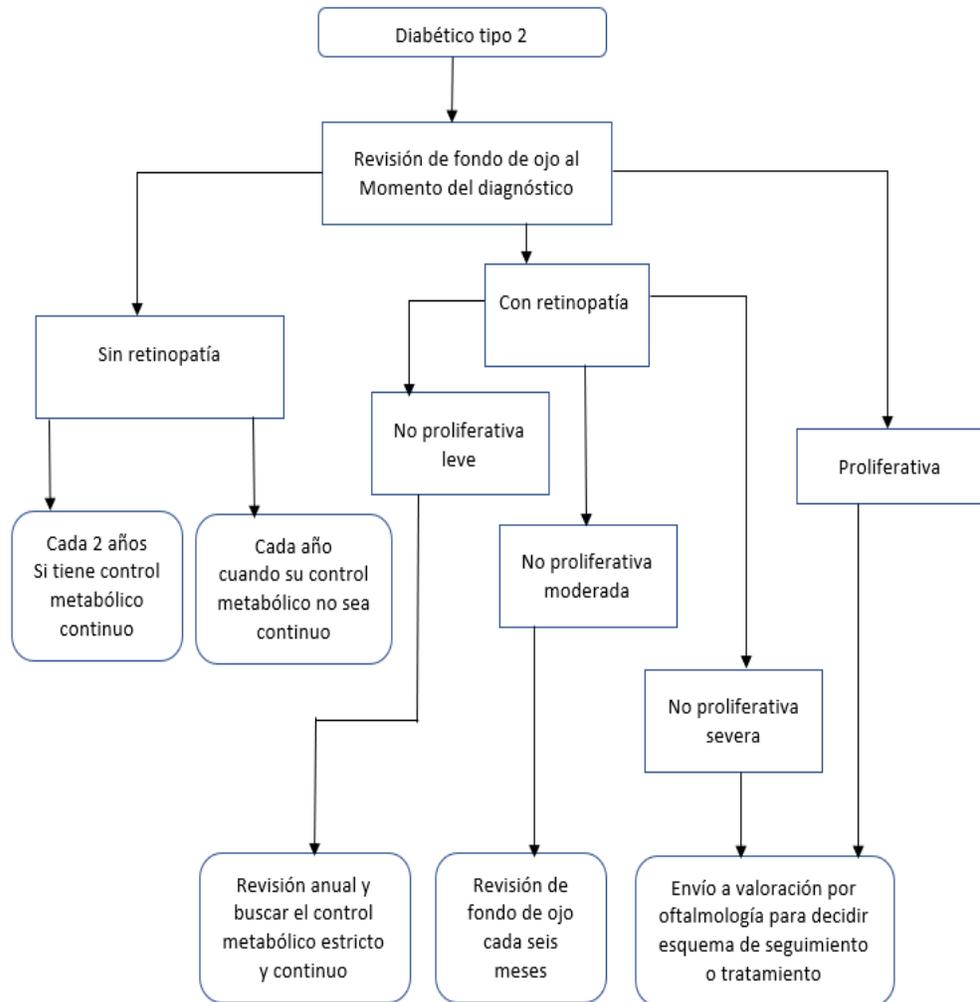


Figura 14. Procedimiento de evaluación para pacientes diabéticos tipo 2.

3.1.3 Diseño

El estar utilizando un enfoque cuantitativo se ha decidido que el estudio considere un diseño experimental de laboratorio (el otro tipo de diseño es de campo), algunos también lo denominan diseño bibliográfico.

El diseño bibliográfico se considera “cuando se recurre a la utilización de datos secundarios, es decir, aquellos que han sido obtenidos por otros” (Tamayo, 2012, p. 113).

Se busca realizar un estudio de las imágenes de fondo de ojos para determinar las características que nos permita determinar la presencia de microaneurismas, a través de una red neuronal artificial.

Como se mencionó anteriormente, las redes neuronales tienen tres tipos de capas: **capa de entrada** que permite aceptar los datos de entrada, que pueden ser imágenes, **capa oculta** que no tiene contacto con el exterior y permite realizar todo el proceso y finalmente la **capa de salida** que brinda el resultado una vez culminado el proceso.

En la presente investigación, como se muestra en la figura 15, se está utilizando redes neuronales convolucionales porque son más apropiadas para trabajar con imágenes, es decir: se utilizará una capa de entrada, una capa convolucional, una capa de agrupación (reducción) y una capa de salida.

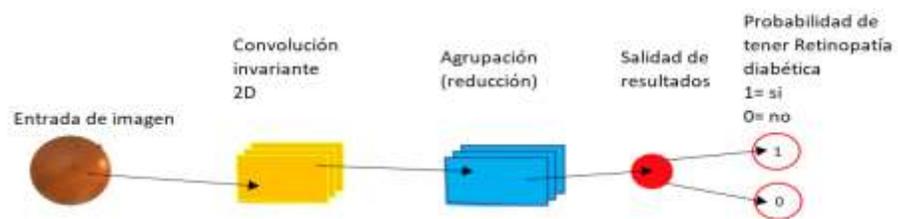


Figura 15. Configuración de la red neuronal convolucional.

Fuente: Elaboración propia.

La **capa entrada de imagen** permite aceptar todas las imágenes de fondo de ojos, la **capa convolución invariante 2D** utilizando la operación de convolución en la imagen, luego aplica filtros o kernel para obtener características de dicha imagen, la **capa agrupación o reducción** utiliza la operación max-pooling ,permite reducir el ancho y alto, a pesar que esta reducción significa pérdida de información de la imagen, beneficia al proceso

general en un menor número de cálculos y finalmente la **capa de salida** que brinda el resultado una vez culminado el proceso, es decir 1 si hay presencia de retinopatía diabética o 0 si no hay presencia de retinopatía diabética.

3.2 Población y muestra (escenario de estudio)

La población son todas las personas que tengan algún problema con su retina y que se han acercado a un centro oftalmológico. En este proyecto se está considerando las imágenes de fondo de ojo que se han realizado a personas que tienen una retina normal y aquellas que tiene alguna enfermedad relacionada a la retina diabética. Para ello se está utilizando imágenes que han sido captadas con equipos especiales denominados oftalmoscopio, con el avance de la tecnología se han ido modernizando y algunos de ellos utilizan la auto fluorescencia para capturar imagen del fondo de ojo, permitiendo hacer un estudio más preciso con respecto a la retinopatía diabética.

Se necesita equipo sofisticado para capturar imágenes del fondo de ojo, por esta razón la muestra que se utiliza está conformado por una base de datos de la plataforma Kaggle, de ella se descargaron alrededor de 88000 imágenes en formato Joint Photographic Experts Group (JPEG), conformado de la siguiente manera 35.200 de imágenes para entrenamiento y 52.800 para validación. Tenían imágenes de ojo izquierdo y derecho por cada paciente y a la vez el nivel de RD, esto último se encontró en un formato cv, obtenido también en la descarga. Esta base de datos está a disposición de cualquier persona que desea realizar un estudio relacionada a la retinopatía diabética. La figura 16 muestra la imagen de fondo de ojo con presencia de microaneurismas (imagen tomada de E_ophtha, 2013).

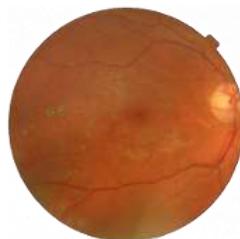


Figura 16. Imagen de fondo de ojo con microaneurisma.

3.3 Técnicas e instrumentos de recolección de datos (validez y confiabilidad)

Los datos se pueden recolectar utilizando:

Entrevistas: Permite obtener información a través de preguntas en forma personal, directa y verbal.

Encuesta: Se obtiene información tomando una muestra de la población objetivo.

Observación: permite obtener información en forma directa.

Como ya se ha indicado el diseño que se está utilizando es experimental de laboratorio por lo tanto podemos decir que la técnica es de observación indirecta ya que se está considerando imágenes de fondo de ojo que se han seleccionado y están contenidas en la base de datos de la plataforma Kaggle.

La observación indirecta “se presenta esta técnica cuando el investigador corrobora los datos que ha tomado de otro” (Tamayo, 2012, p. 188).

3.4 Descripción de procedimientos de análisis

Ahora hay, por una variedad de razones, mucho interés en desarrollar algoritmos informáticos automatizados para detectar y cuantificar características y lesiones que ocurren en imágenes retinianas, es decir, imágenes de la retina humana. La idea es que una imagen de la retina se pueda capturar digitalmente en la fuente y una computadora se pueda utilizar para analizar la imagen e informar sobre la presencia de la enfermedad o la progresión de la enfermedad desde la última visita del paciente. Una tarea más simple de particular interés es reconocer la presencia o ausencia de alguna enfermedad específica adecuada para los programas de detección ocular de la retina. Al automatizar esta tarea, el programa de detección puede volverse más barato, más eficiente y fácil de operar en centros remotos. También existe el potencial de liberar a los oftalmólogos, que son escasos en todo el mundo, para otro trabajo.

El diagnóstico precoz para determinar si una persona tiene retinopatía diabética se puede realizar a partir de la detección de microaneurismas. Los microaneurismas son el primer signo clínico de retinopatía diabética y aparecen como pequeñas manchas rojas en las imágenes del fondo de retina. Los microaneurismas son de color rojizo con un diámetro inferior a 125 μm (Noushin Eftekheri et al., 2019).

El problema para la detección automatizada de la patología retiniana cuando se usan imágenes comprimidas con compresión JPEG es que ciertas características de interés (como lesiones pequeñas) ocurren en la misma escala que los artefactos introducidos por la compresión. Algunos algoritmos de detección automatizados propuestos se basan en la detección de lesiones pequeñas y es probable que la compresión JPEG tenga un efecto adverso que puede ser clínicamente intolerable. El efecto de la compresión JPEG en la detección automatizada de la patología retiniana, exige que se realicen más estudios para conocer con más certeza el verdadero efecto que se origina en la compresión JPEG.

Capítulo IV: RESULTADOS Y ANÁLISIS DE RESULTADOS

4. Resultados y análisis de resultados

Antes de pasar desarrollar este capítulo, sabemos que en la mayoría de los países es muy poco lo que se ha logrado con el diagnóstico precoz como una medida que permita disminuir pacientes con retinopatía diabética, esto no es ajeno a nuestro país. Sabemos que en nuestro país en realidad no existe el diagnóstico precoz, lo que existe es prácticamente el tratamiento de la enfermedad, es decir, cuando el paciente se acerca a un centro de salud es cuando la enfermedad ya empezó o está avanzada.

Solo algunos hospitales y clínicas de nuestro país pueden dar este tipo de tratamiento, la razón principal es la inversión que deben realizar para adquirir los equipos medidos, estos equipos tienen un costo que muchas veces no lo pueden cubrir, porque van desde unos miles de dólares hasta cerca de medio millón de dólares, como lo evidenciamos más adelante.

Todo centro de salud ya sea hospital o clínica, por lo general siguen estos pasos cuando una persona se acerca por problemas en el ojo: después de sacar una cita, se acerca al centro de salud y se le aplica unas gotas a los ojos que permiten dilatar las pupilas, es decir, los abren más, de esta manera el oftalmólogo puede ver mejor dentro del ojo. El paciente debe esperar de 10 a 15 minutos para dicha dilatación, seguidamente el oftalmólogo haciendo uso de un equipo para observar el fondo de ojo determinar, de acuerdo a su experiencia y conocimientos: vasos sanguíneos anormales, hinchazón, sangre o depósitos de grasa en la retina, crecimientos de nuevos vasos sanguíneos, anomalías del nervio óptico, entre otras anormalidades, que den a entender que hay presencia de retinopatía diabética, de ser así procede a continuar con el tratamiento más apropiado para que se implemente en el paciente. Si el oftalmólogo tiene los equipos necesarios podría tomar fotografías al interior de los ojos, las cuales examinara para determinar vasos sanguíneos cerrados, rotos o que están perdiendo líquido. El paciente debe esperar un tiempo para que, su visión vuelva a su estado normal y así poder retirarse del centro de salud, esto puede tardar 20 a 40 minutos, dependiendo del organismo de la persona (Mayoclinic,2020).

El trabajo está desarrollado para ayudar a los oftalmólogos a que realicen un diagnóstico precoz, para ellos utilizamos visión computacional con redes neuronales convolucionales,

estas redes son muy apropiadas para el procesamiento de imágenes, pero exige que se realice todo el proceso en un servidor (back end), es decir, se apreciara como resultados lo que se visualice en la pantalla del servidor y no las interfase tradicionales que se apreciarían en un sistema front end. Trabajos parecidos con visión computacional y redes neuronales se pueden apreciar en algunas publicaciones de estos últimos años. Algunos de ellos están orientados al reconocimiento de escritura a mano e incluso también utilizan la biblioteca keras (Shamshad Ansari,2020).

En esta parte desarrollamos el esquema que se ha presentado en el capítulo anterior para mostrar el contenido de la tesis. De forma resumida, se describirán los aspectos abordados a lo largo de la investigación realizada, los resultados obtenidos y su análisis. Todo ello se recoge en el compendio de publicaciones que acompaña la tesis. Se construye aquí un hilo argumental que facilita la presentación del trabajo llevado a cabo, relacionándolo con las publicaciones compendiadas, de manera que queda justificada nuevamente su unidad temática. La conexión entre el tema tratado en cada apartado y la publicación o las publicaciones en las que aparece irá indicando, mediante las oportunas referencias, a lo largo de todo el capítulo. En algún caso, se presentan resultados obtenidos muy recientemente que no están incluidos en ninguna de las publicaciones del compendio. Esta circunstancia también se hará explícita en su momento.

4.1 Resultados

Etapas de la metodología del Proyecto

Las enfermedades actuales son tratadas de formas directa, es decir, un médico especialista debe revisar y realizar análisis al paciente, la cual toma un tiempo determinado para conocer el diagnóstico del paciente. Para la detección de la Retinopatía Diabética (RD) en los pacientes debe cumplir ese mismo mecanismo, por tal motivo se busca la necesidad de automatizar este proceso desarrollando una herramienta de detección automática de la RD mediante técnicas de Deep Learning. El proyecto utiliza una base de datos, con una gran cantidad de imágenes, con el fin de tener un modelo neuronal óptimo y no obtener un sobreajuste del modelo. A

continuación, se desarrolla cada etapa de la metodología utilizada en esta investigación.

Análisis de herramientas

El análisis de las herramientas a utilizar para el desarrollo de del modelo deep learning para la clasificación de la RD es un paso sustancial, debido a que uno de nuestros objetivos específicos es reducir los costos de diagnóstico ya sea utilizando una nueva tecnología o mejorando el software o hardware a utilizar para el diagnóstico de RD.

A continuación, se realizará un análisis referente al hardware(servidor) a utilizar para la creación del modelo neuronal.

Tabla 5. Características de los servidores en el mercado.

Tipo	Servidor A	Servidor B	Servidor C
vCPU	8	32	64
RAM (GB)	61	244	488
Disco Duro (GB)	500	1000	2000
Memoria GPU (GB)	16	64	128
Sistema Operativo	Linux	Linux	Linux
Precio x Hora	2 dólares	8 dólares	16 dólares

Elaboración: Propia

En la tabla 5 se puede observar 3 tipos de servidores con distintas características para la creación del modelo neuronal. Los precios son aproximados a los mercados brindados por AWS, IBM, Azure y Google Cloud.

Para el desarrollo de esta investigación seleccionamos el servidor A, debido a que trabajos similares (Retamozo Sánchez, n.d.) utilizaron servidores con las características parecidas para la creación del modelo neuronal propuesto.

Ahora se debe seleccionar un adecuado software para la creación del modelo neuronal. Para esto se realizó un análisis sobre las lenguas de programación más usados en el desarrollo de modelo basados en Deep learning.

A continuación, se muestra una tabla comparativa sobre los 3 lenguajes más usados para el desarrollo de modelos basados en Deep Learning.

Tabla 6. Características de diferentes lenguajes de programación. Elaboración propia

Aspectos	Cualidades	Python	R	Matlab
Programación	Proporciona pista de errores	SI	NO	SI
	Programación de alto nivel	SI	SI	SI
	Se trabaja con diferentes IDE'S	SI	NO	NO
Idioma	Inglés	SI	SI	SI
	Español	SI	NO	NO
Tipo de Aplicaciones	Escritorio	SI	SI	SI
	Web	SI	SI	NO
Data Scientists	Minería de Datos	SI	SI	NO
	Análisis de datos	SI	SI	SI
	Deep Learning	SI	NO	NO
Curva de Aprendizaje	Lenta y complicada	NO	SI	SI
	Rápida y fácil	SI	NO	NO
Matemáticas	Matemáticas Financiera	SI	SI	SI
	Estadísticas	SI	SI	SI
	Vectores, array matrices	SI	SI	SI
	Gráficos estadísticos	SI	SI	SI
	Gráficos 3D	SI	SI	SI

Elaboración: Propia

Según la tabla 6 se puede observar que el lenguaje que mejor uso tiene para nuestro caso es el Python, por esta razón utilizamos la versión Python 3.6.6, gracias a su facilidad de uso, extensas bibliotecas y la forma en cómo trabaja con la inteligencia artificial. Este lenguaje de programación es muy ágil y ligero para el entrenamiento de cualquier red artificial. Además, se puede encontrar una extensa cantidad de información acerca de su sintaxis. Otro lenguaje que estudia Machine Learning y

Deep Learning es R, pero este no se escogió por la sencilla razón de que es reciente en el mercado y se tiene poca información en la web, de misma forma en Matlab. Cabe indicar que el lenguaje Python es Open Source, de libre uso, sin ningún costo. La selección del Entorno de Desarrollo Integrado (IDE) se seleccionó basados en los entornos más usados en Linux para Python y en deep learning. En este caso se decidió trabajar con Jupyter, el cuál es un proyecto de Ipython considerado como una de las mejores plataformas para la Inteligencia Artificial. Este estudio se basa en la programación paralela que maneja la plataforma web Ipython Notebook a través del kernel de Ipython.

Para poder trabajar sin problema en Jupyter Notebook se consideró a Anaconda 4.5.9, la más grande distribución de Python. Al principio se utilizó su entorno base y después de tantas pruebas, el entorno antes mencionado se empezó a dañar. Comenzó dando errores de versiones en bibliotecas hasta el punto de ya no querer instalar nada. Para esto se procedió a borrar todo y se volvió a instalar desde cero la distribución de anaconda, pero esta vez se consideró la creación de un ambiente. Esto fue de una u otra forma lo más factible y rápido, ya que si se volvían a dañar (que fue lo que pasó nuevamente por versiones y bibliotecas), no pasaba en toda la base sino solo el entorno creado en ese momento.

Recolección de imágenes

En esta etapa se explica el tipo de imagen y el proceso que se realiza para poder utilizarlo en el modelo neuronal artificial. Como ejemplo a esto se hace hincapié en los objetivos específicos de forma breve y las medidas que se deben tomar para alcanzar cada uno de ellos conforme a la creación del modelo.

La búsqueda para conseguir la cantidad de imágenes de la retina necesarias para el entrenamiento de un modelo lo suficientemente aceptable para la clasificación de la RD fue una tarea complicada, debido a que se buscó centros oftalmológicos públicos y privados que deseen participar en el proceso de investigación, por otro lado, se buscó estas imágenes en base de datos públicos en la web (crowdsourcing). Todo con la finalidad de recolectar la mayor cantidad de imágenes para que el programa pueda aprender sin ningún inconveniente.

También se analizó diferentes lenguajes de programación que ayuden al estudio de las redes neuronales artificiales, la cual es analizado en (García Navarro et al., 2015). Los entornos de desarrollo integrados (IDE) o editor de texto son herramientas también importantes para este tipo de programación por lo que al final se indica cuál resulta más rentable en este proyecto. A pesar de varias investigaciones en la web no se llegó a encontrar un modelo o sistema idéntico al trabajo proyectado. Es decir, el modelo se creará desde cero, escogiendo una base de datos ya existente para nuestro trabajo, algunos de ellos proporcionado por la plataforma Kaggle.

Por último, se presenta un diseño del modelo realizado con las diferentes técnicas estudiadas a lo largo de la investigación. El mismo demostrará su funcionalidad detectando los diversos signos de la RD y logrando predecir si el paciente tiene o no la enfermedad.

Base de datos

Para obtener buenos resultados en esta investigación, se buscó imágenes médicas en hospitales públicos y centros oftalmológicos privados. Sin embargo, entre estos, no se obtuvo la cantidad deseada para este tipo de proyectos. Además, se tenía que pedir por cada paciente un permiso médico en donde me otorgue la responsabilidad de estas. Entonces, se optó por buscar imágenes médicas en diferentes sitios web que ayudan a la investigación científica (crowdsourcing). Entre ellos se encontraron Kaggle la cual fue escogida para la investigación.

Estas imágenes le pertenecen a Eyepacs y se puede encontrar en Kaggel. Se descargaron alrededor de 88.000 imágenes en formato .JPEG, del cual se conformaba por 35.200 de imágenes para entrenamiento y 52.800 para validación. Tenían imágenes de ojo izquierdo y derecho por cada paciente y a la vez el nivel de RD, esto último se encontró en un formato cv, obtenido también en la descarga.

Preprocesamiento de imágenes

Lamentablemente se observó que las imágenes estaban en diferentes resoluciones y tenían mucho ruido, como: luminosidad (subexpuesta y sobreexpuesta), nivel de zoom, algunas tenían manchas, estaban viradas, a la mitad, manchadas, etc., (se

asume que fueron tomadas por dispositivos de diferentes calidades). Algo importante que se puede indicar, es que una cantidad muy baja estaba mal etiquetada. A continuación, ejemplos de imágenes dañadas, existentes en la base de datos kaggle.

Imágenes con diferentes luminosidades claras, en la figura 17, se observan tres figuras: la imagen a) es de un ojo izquierdo y la b) con la c) son ojos derechos. En la a) su luminosidad clara está a lo largo de lateral izquierdo, en la b) se encuentra en la parte superior derecha y en la imagen c) su luminosidad oscura está en la parte derecha.

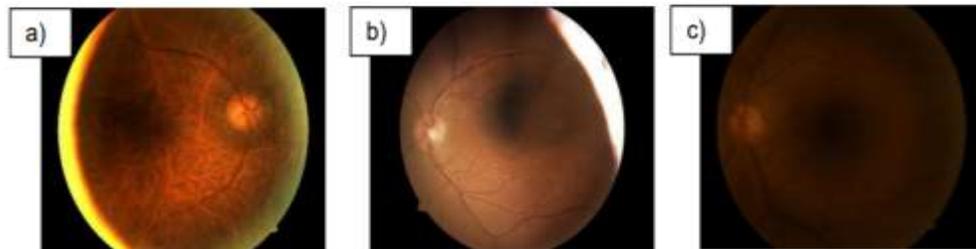


Figura 17: Retinografía con diferentes luminosidades

Imágenes con manchas y distorsionadas, En la figura 18, se puede encontrar una imagen distorsionada con un color diferente al original e imagen con una retinografía con luminosidad oscura y manchas de dedos sobre ella.



Figura 18: Retinografía con manchas y distorsionada

Diferente zoom, en la figura 19 se encuentra, la imagen a) con un zoom extremadamente cerca y en b) con un zoom lejos.

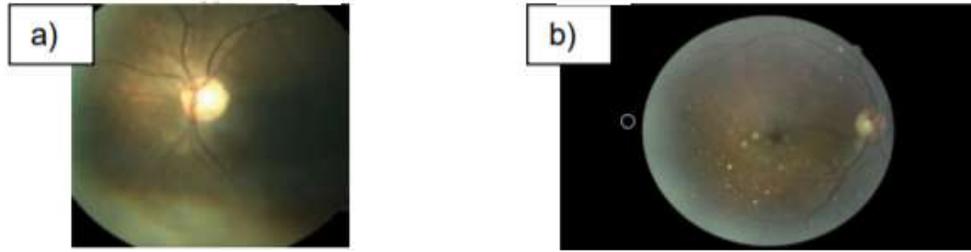


Figura 19: Retinografías con diferente zoom

Diferentes focos, diferentes focos se refiere a las distintas posiciones en el que se encuentra el nervio óptico, de la figura 20 en la imagen a) se puede presenciar el foco al lado izquierdo siendo un ojo derecho. Y en la imagen b) se presenta el foco de frente.

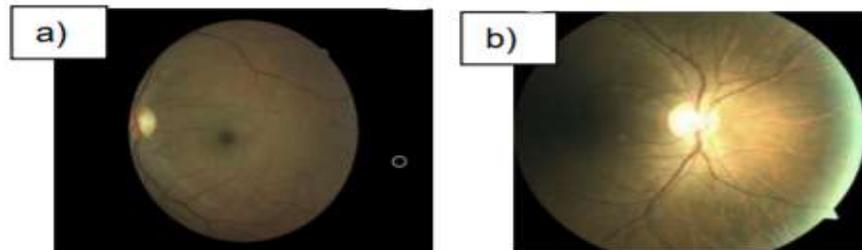


Figura 20. Retinografía con distinta ubicación del nervio óptico

Imagen cortada, en la figura 21 la imagen a) se nota la retina a la mitad y en la imagen b) se ve como hay una retinografía encima de otra.

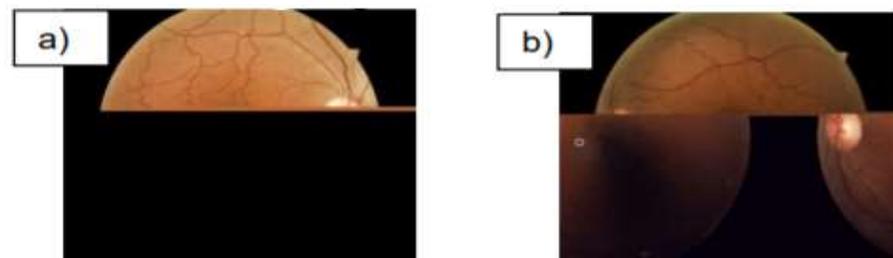


Figura 21: Retinografía con imagen cortada

Imagen sin enfermedad y con enfermedad, en la figura 22 la imagen a) se sin enfermedad y en la imagen b) se ve con enfermedad.

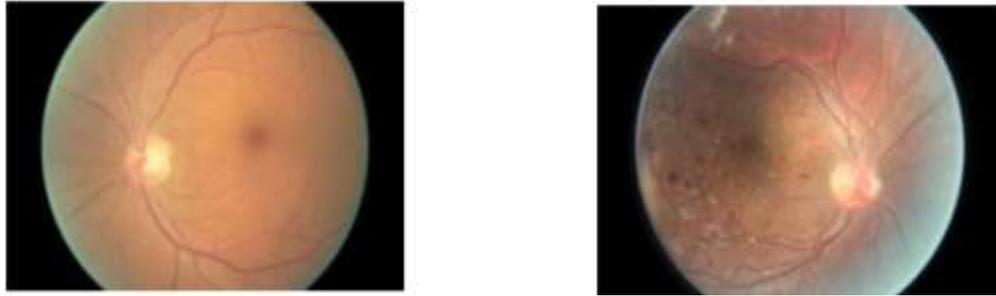


Figura 22: Retinografía sin la enfermedad y con la enfermedad

Mejora de imágenes

El preprocesamiento depende del tipo de red neuronal artificial profunda se va a desarrollar, si es bien cierto, las imágenes no necesitan un filtro a priori, pero debido a los resultados obtenidos a través de pruebas, se le dio un preprocesamiento con la finalidad que el modelo neuronal pueda entrenar de manera más fácil, los parámetros diminutos de la enfermedad del ojo.

Mientras mayor es el tamaño de la retinografía, mayores son los recursos tecnológicos que ocupa para aprender. Para esto se necesita un tamaño considerable, que no deje pasar por alto el estudio de las retinas.

Las imágenes tienen diferentes dimensiones, la mayoría son demasiadas grandes y rectangulares. Se revisó algunos métodos de preprocesamiento de imagen y se llegó a la conclusión de unir varios de ellos, con la finalidad de que se obtengan mejores resultados. Se utilizaron bibliotecas de OpenCV y Pillow para la edición y presentaciones de las imágenes. Además, se utilizó la biblioteca Numpy, importante para convertir cada fotografía en una matriz y poder procesarla de mejor forma. En la figura 23, se encuentra la imagen original antes de ser procesada.



Figura 23: Retinografía original

A continuación, describiremos los pasos para mejorar las imágenes:

- **Recorte de la imagen:** Algunas imágenes contenían la fecha en que fue tomada o de donde fue adquirida la fotografía, estas historias estaban en la parte posterior o inferior de la misma. Se consiguió un método que evita que el proceso de recorte confunda a las historias de cada imagen con un borde o esquina. Este consistía en recorrer la imagen desde adentro hacia afuera indicando según diferentes factores cuando ya era negro, se estimaba un fondo. Con el fin de que todas las imágenes tengan la misma dimensión en cuanto a la forma de la retina, se procedió a realizar análisis de sus radios. Se calculó el mismo obteniendo primero su diámetro a través de la fila 256, quién era el reglón a la mitad de la retina. Una vez obtenido su radio se procede a coger esa variable para llevarla a redimensión del paso 4. En la figura 24 se observa cómo se recortó la imagen.

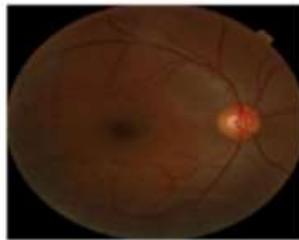


Figura 24: Recorte de retinografía

- **Convertir la imagen al 50% gris:** resulta que las imágenes tienen mucho color rojo en el globo de retina. Este color tan fuerte no deja ver las características minúsculas de la enfermedad. Como las hemorragias que a fin de cuentas es el mismo color de la retina. Para poder solucionar este proceso, se decidió primero convertir la imagen a gris, luego a contraste azul y se finaliza con el 50% de gris. Concluyendo que la mejor opción sea la última, ya que la retina junto con el fondo de la imagen, quedan con un tono muy similar. Y las características se resaltan con una mejor tonalidad. Para comprender este proceso es bueno recordar que, 1 Byte tiene 8 bits, y 1 bit puede almacenar 2 valores, de los cuales los dos son booleanos. 2^8 , da como

resultado 256. La imagen al final del preprocesamiento es de 512x512, es decir que esta cuenta con 8bytes (64bits). De la cual 7bytes son para los colores de RGB (Red, Green, Blue) y 1byte se usa para dar un efecto de transparencia a la imagen. De este último byte, se extrae el 50% de transparencia, es decir que la función lo que hace es reducir su RGB al 50% y colocar el 50% de la escala gris (128). Gaussianblur, es la función que ayuda a escoger el 50% de RGB. En la figura 25, se observa cómo queda la imagen al 50% gris.

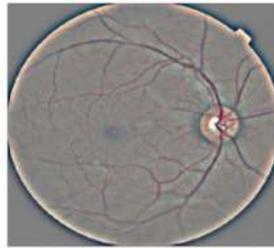


Figura 25: Retinografía al 50% gris

- **Aislamiento del borde:** Aquí se recortó el 10% del borde de la retina, conservando un 90% de imagen nítida. Este proceso se hizo con la finalidad de que la imagen no tenga un borde muy luminoso como se obtiene al finalizar el proceso anterior. Se comienza creando una imagen a B/N con las mismas dimensiones que la original, lo negro es el fondo y lo blanco es el resultado del 90% de radio de la retinografía original. Al final se realiza una operación matemática quedando como resultado la retinografía con el borde luminoso. En la figura 26 se observa en la imagen a) la nueva fotografía creada a B/N y en la imagen b) el procesamiento final quitando el borde luminoso.

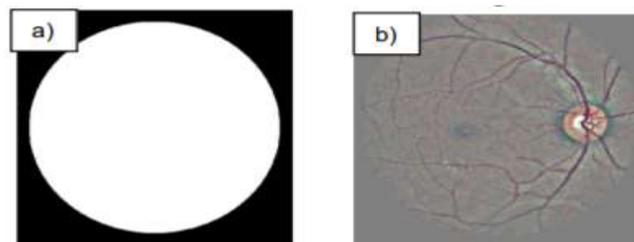


Figura 26: Aislamiento de borde de retinografía

- **Redimensionamiento:** Para este método se probaron algunas pruebas de entrenamiento para indicar cuál es la mejor dimensión en que la red estudia mejor los parámetros de las retinografías. Pudiendo deducir que entre 64x64 y 128x128, a la red se le complica aprender, debido a que son parámetros muy minúsculos y por ende en una imagen pequeña va a ser difícil de extraer. A partir de 256x256 la imagen tiene un acierto más alto. Por ende, se decide que el mejor método de procesamiento para este proyecto será 512x512. Para esto se utiliza el método *resize* de OpenCV, que permite dimensionar una imagen, agregando un fondo negro sin que se pierda el aspecto de la retina. Como formato de arreglo para convertir la imagen en matriz se escogió *uint8* para que las imágenes no ocupen tamaño incensarios en la memoria del disco. Gracias a todos esos parámetros se pudo obtener imágenes con menos peso, más centradas y más características para la red. En la figura 27, se observa una imagen con el preprocesamiento finalizado, con una dimensión de 512x512.

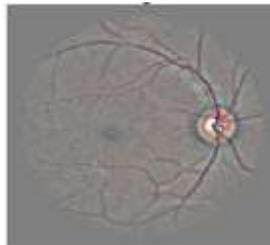


Figura 27: Redimensionamiento de la retinografía

Repositorio final

La base de datos de Kaggle se tuvo que reducir y filtrar como se mencionó anteriormente con los distintos métodos de filtro utilizando la herramienta OpenCV, por lo tanto, se creó otras carpetas. El proceso de filtro duro aproximadamente 2 semanas debido que hay imágenes que se tuvieron que filtrar de forma manual.

Al final de todo el preprocesamiento se obtuvo una carpeta llamada "imágenes_investigación", la cual dentro de esta carpeta se encuentra la carpeta llamada "imágenes_kaggle", en ella se encuentran todas las imágenes del repositorio kaggle sin preprocesamiento. Además, hay otra carpeta llamada

"imágenes_filtradas", donde se encuentran las imágenes pre procesadas pero ordenadas en tres carpetas llamadas "imágenes_train", "imágenes_dev" y finalmente "imágenes_test", estas contienen la cantidad de imágenes necesarias para cada etapa de entrenamiento, validación y prueba del modelo que respectivamente son de 8000, 1000 y 1000 imágenes por cada carpeta, siendo un total de 10000 imágenes preprocesadas.

Tabla 7: Cantidad de imágenes preprocesadas

Tipo de carpeta	Cantidad	Porcentaje %
Imágenes_train	8000	80
Imágenes_dev	1000	10
Imágenes_test	1000	10
Total	10000	100

Elaboración: Propia

Cabe mencionar que cada imagen fue renombrada con un código que identifica el tipo de imagen, es decir que la imagen que muestra es de una persona con la enfermedad o no, este paso de etiquetado es muy importante para el entrenamiento del modelo.

Creación del modelo neuronal

Para la construcción del modelo neuronal, se debe tener listas las carpetas de Imágenes_train (entrenamiento), Imágenes_dev (validación) e imágenes_test (prueba). En la carpeta de entrenamiento y validación deben estar las imágenes preprocesadas. Se debe tener en cuenta que la carpeta de entrenamiento es la carpeta que contiene la mayor cantidad de imágenes para que pueda el modelo neuronal entrenarse de una buena manera.

Para la construcción de la red neuronal convolucional se utilizó varias bibliotecas, pero la principal es Keras. Estas son las principales importaciones que no deben faltar en una red convolucional y se muestran en el siguiente Figura 28.

línea 1	<code>import tensorflow as tf</code>
línea 2	<code>from tensorflow.keras import layers</code>
línea 3	<code>from tensorflow.keras import preprocessing</code>
línea 4	<code>from tensorflow.keras import models</code>
línea 5	<code>from tensorflow.keras.layers import Conv2D</code>
línea 6	<code>from tensorflow.keras.layers import Dense</code>
línea 7	<code>from tensorflow.keras.layers import Flatten</code>
línea 8	<code>from tensorflow.keras.preprocessing import image</code>
línea 9	<code>from tensorflow.keras.layers import MaxPooling2D</code>
línea 10	<code>from tensorflow.keras.models import Sequential</code>
línea 11	<code>import numpy as np</code>
línea 12	<code>from keras.preprocessing.image import ImageDataGenerator</code>

Figura 28: Importaciones de bibliotecas importantes

Según la figura 28 la línea 1 se importa el framework tensorflow que contiene los métodos de Deep Learning. Hay dos formas de iniciar un modelo por secuencia o por grafos. En este caso se inicia por secuencia, ya que las redes neuronales se conectan secuencialmente una detrás de otra. En la línea 2 se importa las capas para trabajar. En la línea 3 el método para preprocesar las imágenes que vamos a utilizar para el entrenamiento y la prueba. En la línea 4 se importa los modelos de Deep Learning. En la línea 5 se importa Conv2D o también Convolutional2D, esta realiza el primer paso a la red neuronal convolucional el cuál es la convolución. Se utiliza 2D debido a que la imagen se convierte en una matriz de 2 dimensiones, para videos se utiliza Conv3D (la tercera será el tiempo). La línea 6 el método Dense que lo utilizamos para realizar la conexión completa de la red. En la línea 7 importamos el método Flatten que ajusta las imágenes a procesar. En la línea 8 el método para poder trabajar con imágenes. En la línea 9 se importa MaxPooling2D, se la utiliza para operaciones de agrupamiento. Se la utiliza en el proceso de creación de una RNC para escoger el valor máximo, mínimo o promedio de píxeles. Para esta investigación se utiliza el nivel máximo de píxeles. En la línea 10 se importa Sequential para iniciar el modelo de forma secuencial. En la línea 11 importamos numpy una biblioteca para utilizar método matemáticos y finalmente en la línea 12 importamos ImageDataGenerator para generar imágenes y probar nuestro modelo propuesto.

Luego de haber importado se crea el modelo en forma secuencial, seguida de la cantidad de capas que desee colocar. Keras tiene el privilegio de leer todas las capas y predecir la red que quiere el usuario, a partir de la primera. Por lo general solo establece dimensiones para la entrada de la primera capa en una RNC.

Para obtener un modelo óptimo se experimentó con diferentes tipos de capas utilizadas en el proceso de imágenes a través de Deep Learning. Se trabajó en una red entrenadas desde cero, para profundizar en el estudio. A través de pruebas se modificaron parámetros de errores específicos que se presentaban ante un sobre entrenamiento o procesamiento de CPU. Además de los problemas que se daban por clases que no estaban balanceadas en su clasificación.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 510, 510, 16)	448
max_pooling2d (MaxPooling2D)	(None, 255, 255, 16)	0
conv2d_1 (Conv2D)	(None, 253, 253, 16)	2320
max_pooling2d_1 (MaxPooling2D)	(None, 126, 126, 16)	0
conv2d_2 (Conv2D)	(None, 124, 124, 32)	4640
max_pooling2d_2 (MaxPooling2D)	(None, 62, 62, 32)	0
flatten (Flatten)	(None, 123008)	0
dense (Dense)	(None, 96)	11808864
dense_1 (Dense)	(None, 1)	97
Total params: 11,816,369		
Trainable params: 11,816,369		
Non-trainable params: 0		

Figura 29: Modelo Neuronal en Keras

En la figura 29, se encuentra el modelo propuesto. Si bien es cierto es un modelo básico pero muy representativo, debido a que sigue los parámetros que se estudiaron a través de esta investigación. Estas mismas capas pueden ser utilizadas para otros tipos de entrenamiento en la red a través de imágenes.

Validación y prueba del modelo

Antes de hablar del entrenamiento y validación, se hace un resumen de lo que son las épocas. Para la inteligencia artificial una época significa un pase de entrenamiento y validación completa. El entrenamiento y la validación se ejecutan las veces que el programador crea conveniente y sirve para dar un buen entrenamiento a la red. Mientras más épocas mejor aprende el programa, hay que tener en cuenta y equilibrar el número de épocas con el número de imágenes, demasiadas épocas llevan a un sobreentrenamiento.

Después que se ha construido la red neuronal, se procede a ingresar las imágenes con la finalidad de entrenar el modelo propuesto. Cabe recalcar que no solo se entrena, sino que también se ajusta un modelo guardado. Una vez que se cargaron las imágenes, se llama a la función `fit()`, con la cual se comienza el entrenamiento.

Aquí la red valida por sí sola, si su eficiencia de entrenamiento fue el correcto o no. El conjunto de imágenes que califica son los que están dentro de la carpeta de `test_set` y en caso de ser incorrectos ajusta sus parámetros para la próxima época.

Para que el modelo tengo la mejor exactitud se realizaron varias pruebas y ajustes tanto a la arquitectura del modelo neuronal como cambiar los hiperparametros del modelo. Las capas no cambiaron por la forma de entrada de imágenes. Para ese momento recién las imágenes de la retina estaban en su etapa de clasificación. Así que se decidió por realizar la prueba con 400 imágenes, 200 en cada una de sus clases. Para la validación se utilizaron 200 retinografías más en total. Al poder ejecutar el programa se notó que las retinografías se demoraban mucho en ser procesadas. Este procesamiento en el servidor A, duró aproximadamente 4 horas en su primera época de 15. Se decidió detenerlo y dejarlo por 10 épocas demoró alrededor de 2 días en entrenarse. Se obtuvo como resultado un sobreentrenamiento de la red, es decir la RNC no aprendió sino más bien se memorizó las imágenes. Este sistema no era capaz de predecir retinografías fuera de las que se habían entrenado, además a eso tenía un 90% de error, ya que a la mayoría de las imágenes decía que, si tenía la enfermedad, aunque no la tuviera dentro de la carpeta de entrenamiento.

Se decidió primero probar con 5 etapas en el servidor A, pero cuando iba por su tercera época salió dead kernel (Kernel muerto), quizás el motivo fue la gran cantidad de procesos que estaba corriendo en ese momento, como entrenamiento e investigaciones para la tesis. Luego se decidió probar con 1 época, esta se ejecutó de manera normal y su primer error fue el de imagen truncada. Esto significa que el modelo no estaba aprendiendo a la perfección ya que las imágenes que estaban dentro de las 5.000 eran de alta calidad con resoluciones muy grandes y el modelo hacía que se cortaran a una dimensión de 64x64 para calcular su entrenamiento. Se trató de buscar una solución y lo que más se resaltó entre ellas es mandar el error por verdadero. Es decir, forzar al modelo a que lea la imagen y convertirla en 64x64. Se volvió a correr el modelo en el servidor A, por una época y no presentó error. Al finalizar su entrenamiento se notó que su acierto y error no eran los que se esperaba, no predecía con exactitud y en 80% de las imágenes ingresadas, el modelo se equivocó.

Se analizó que cada imagen que pasaba por el ciclo se preprocesaba, se guardaba en memoria y en una carpeta, luego se borraba en la RAM para no tener ocupado espacio innecesario en la memoria. Se logró notar que la mayor parte del trabajo en un procesamiento lo tiene la memoria RAM. Al principio se mandaron todas las 12.000 imágenes a preprocesar. Pero esto elevó a una gran cantidad la memoria de 32GB por lo que se eligió configurar un parámetro que escoja grupos de imágenes a preprocesar. Se dividió por grupos de 50 imágenes las 8.000 guardadas en la carpeta “no”, dando como resultado 160 grupos. Después el programa empezó a escoger el primer grupo de 50 fotografías para mandarlas a preprocesar y las guardaba en un nuevo directorio. Luego de terminar el primer grupo de 50 imágenes, iba con el segundo y así sucesivamente, hasta llegar al grupo 160. Lo mismo hizo con las imágenes del “si”. Además, como formato de arreglo para convertir la imagen en matriz se escogió uint8 que solo ocupa 1 byte (1). Se escoge este valor para evitar posibles turbaciones o distorsiones en la intensidad de la imagen. Se recuerda que la imagen preprocesada tenía un 50% en RGB por ende sus datos en píxeles estaban dentro de 0 a 255 (enteros). Sus filas y columnas quedaron como 512x512. En su totalidad cada imagen

preprocesada tenía un valor de $512 \times 512 \times 1 = 786.432$ píxeles, convirtiendo esto a 0.78Mb de memoria en el disco. Ocupando un total de 9.36GB (por 12.000 imágenes) para almacenar.

También se puede escoger el tipo de datos float32 que ocupa 4bytes, pero cada imagen llegará a tener un valor de 3.14Mb, gastando memoria en disco innecesarios. (Scikit-Image). Cabe recalcar que este procedimiento hizo que la memoria no se eleve a su tope, sino al contrario trabajó de muy buena manera para otros tipos de actividades. Luego de este preprocesamiento se añadió una capa de convolución y otra de maxpooling para un mejor aprendizaje de la red, analizando 11816369 parámetros. Quedando el modelo final de la siguiente forma.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 510, 510, 16)	448
max_pooling2d (MaxPooling2D)	(None, 255, 255, 16)	0
conv2d_1 (Conv2D)	(None, 253, 253, 16)	2320
max_pooling2d_1 (MaxPooling2D)	(None, 126, 126, 16)	0
conv2d_2 (Conv2D)	(None, 124, 124, 32)	4640
max_pooling2d_2 (MaxPooling2D)	(None, 62, 62, 32)	0
flatten (Flatten)	(None, 123008)	0
dense (Dense)	(None, 96)	11808864
dense_1 (Dense)	(None, 1)	97
=====		
Total params: 11,816,369		
Trainable params: 11,816,369		
Non-trainable params: 0		

Figura 30: Modelo Neuronal en Keras

Se procedió a guardar el modelo para futuras pruebas, se lo realiza por 1 épocas de 512×512 . Y se tiene como resultados de acierto un 0.6, también se guardó sus pesos. La mayoría de los programas de IA que trabajan con Jupyter no tienen GUI. Esto se debe a la programación paralela que tiene.

4.2 Análisis de resultados o discusión de resultados

La etapa de prueba se realizó con imágenes que la red no haya entrenado o validado, con el fin de probar si funciona o no el modelo. Para esto se tomó imágenes de la carpeta de prueba.

Se desarrolló un código pequeño para seleccionar la imagen a analizar y ver como resultado la imagen elegida, su preprocesamiento y su veredicto. (Es decir si padece o no de RD).

Luego de haber reestructurado la validación, de cada 10 pruebas realizadas 8 resultados fueron acertados por lo que se puede determinar que la credibilidad es de un 80% fiable, el 20% de error se dio debido a que se necesitaba más imágenes (es decir imágenes al momento de entrenar la red). Así mismo se necesita aumentar el número de épocas porque mientras más épocas tiene el entrenamiento su aprendizaje es mayor y por ende sus predicciones son más precisas.

A continuación, se muestra el cuadro con los resultados finales.

Tabla 8: Resultados de la prueba del modelo neuronal propuesto

Nº PRUEBA	CORRECTO	INCORRECTO	RESULTADO	DESEADO	TIEMPO
1	X		0.87401354	SI	12s
2	X		1.0	SI	11s
3	X		1.0	SI	11s
4	X		0.5364356	SI	15s
5	X		1.0	SI	12s
6		X	0.99999845	NO	12s
7	X		1.0	SI	12s
8	X		1.0	SI	9s
9		X	0.2204929	NO	10s
10	X		1.0	SI	27s

Elaboración: Propia.

Como se puede observar en la tabla 8 el modelo tiene un accuracy (fiabilidad de predicción) del 80%, la cual significa que de 100 pruebas solo 20 de ellas pueda fallar.

El nivel de predicción es de PRED (0,20) = 0.80. Sabiendo que para que un modelo predictivo sea aceptable un PRED debe ser mayor a 0.75 (DUNSMORE, CONTE, & SHEN, 1986).

La arquitectura de red neuronal para predecir RD de los pacientes tiene un error absoluto de entrenamiento del 20% y un grado de validez del 80%.

En el anexo 4 se tiene el código utilizado en el proyecto, así como el sustento matemático para cada uno de los algoritmos utilizado en el sistema.

De la misma manera podemos realizar un análisis de los costos de consulta y tiempos involucrados cuando se realiza el diagnóstico de un paciente, para detectar si tiene retinopatía diabética. En la tabla 9, podemos apreciar información de costos y tiempos de algunos centros de salud.

Tabla 9: Costos y tiempos para la detección de la retinopatía diabética

Centro de salud	Costo de la consulta (\$) (1\$=3.4 soles)	Tiempo (minutos)	Técnicas
Hospital Loayza	44 - 59	20 - 30	Angiofluoresceinografía
Hospital Loayza	10	10 - 15	Estudio de retina y fondo de ojo
Hospital Loayza	8	10 - 15	Fondo de ojo
Hospital Cayetano Heredia	7 - 20	10 - 15	Oftalmología
Servi Salud	6	10 - 15	Fondo de ojo
Técnica de Ojos Prueba Laser	74	30 - 40	Angiografía
Instituto Nacional de Oftalmología	26 - 35	20 - 30	Angiofluoresceinografía
Instituto Nacional de Oftalmología	8 - 24	10 - 15	Fotografía de fondo de ojo
Otras	147 - 294	Más de 40	Varias

Elaboración: Propia.

En nuestro país la entidad más especializada en el tratamiento de los ojos es el Instituto Nacional de Oftalmología y ellos tienen diversos tratamientos que ofrecen (INO, 2015), donde la angiografía, como ya se mencionó anteriormente, consisten en utilizar

gotas especiales que después de un tiempo el oftalmólogo puede apreciar mejor el interior del ojo. De la misma manera se ha recabado información en el Hospital Loayza (Hospital Loayza, 2020), también se tiene información del Hospital Cayetano Heredia (Hospital Cayetano Heredia, 2019).

La fotografía de fondo de ojos se puede tomar utilizando un oftalmoscopio que se tiene en una gran variedad de modelos y precios, por ejemplo, la empresa WelchAllyn los comercializa desde \$177 a \$1223. Otra alternativa es utilizar un smartphone que con un dispositivo adicional permite tener fotografías de fondo de ojos y existen empresas que los comerciales con precios bastantes bajos como la empresa D-EYES shop online que los vende entre \$109 a \$435.

El equipo para tomar fotografías de fondo de ojos ZEISS VISUSCOUT 100 tiene un precio de 12771 euros. Pero se puede observar una gran variedad de equipos con sus respectivos precios que están entre \$1000 a \$50000 en la empresa Alibaba (Alibaba, 2020). Otros equipos para realizar diversos tratamientos de la retina pueden ser ofrecidos por la misma empresa antes mencionados, cuyos precios pueden estar entre \$200000 a \$500000 (Alibaba, 2020).

Entonces podemos apreciar que los costos de las consultas no pueden justificar la inversión que la entidad de salud a realizado por la compra de los equipos.

Si se desea hacer uso de los servicios de la nube se podría pagar (Amazon,2020):

Primeros 50 TB/mes → \$0,040 por GB.

Siguientes 450 TB/mes → \$0,039 por GB.

Más de 500 TB/mes → \$0,037 por GB.

Conociendo los diversos precios de los equipos que se podrían utilizar para el tratamiento de oftalmología, para identificar si un paciente tiene retinopatía diabética, se puede observar que utilizando un equipo de aproximadamente \$100, se puede capturar la imagen de fondo de ojo del paciente y con el sistema desarrollado residente en un servidor el costo sería mucho menor, de la misma manera el tiempo se reduciría

para conocer si el paciente tiene retinopatía diabética y así recomendar el tratamiento más adecuado que se le debería aplicar al paciente.

Utilizando la matriz de consistencia, en la tabla 10 comprobamos que se han logrado los objetivos específicos propuestos en nuestro trabajo.

Tabla 10: Logro de los objetivos específicos

Planteamiento del Problemas	Objetivos	Hipótesis	Variables	Indicadores
Pregunta General: ¿Se puede mejorar el diagnóstico precoz de la retinopatía diabética?	General: Mejorar el diagnóstico precoz de la retinopatía diabética utilizando visión computacional.	General: El diagnóstico precoz de la retinopatía diabética se mejora con la visión computacional		
Pregunta Específicos:	Específicos:	Específicos:	Independiente Usar (“si”, “no”) Dependiente Retinopatía diabética identificada usando visión computacional. Retinopatía diabética identificada sin usar visión computacional.	Precisión. 80% No existe el diagnóstico precoz y se realizan varios análisis.
1. ¿Se puede detectar la retinopatía diabética usando visión computacional?	Detección de la retinopatía diabética usando visión computacional.	Se mejorar la identificación de la retinopatía diabética usando visión computacional.		
Si se puede detectar	El sistema la detecta	Si se mejora la identificación de la retinopatía diabética		
2. ¿Se puede disminuir el costo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional?	Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Se disminuye el costo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional.	Independiente Usar (“si”, “no”) Dependiente Costo del diagnóstico precoz usando visión computacional. Costo del diagnóstico precoz sin usar visión computacional.	Costo. \$100 de equipo para tomar la foto y \$0,037 al mes. \$20000 aproximadamente en equipo.
Si se puede disminuir	El sistema lo disminuye	Se disminuye el costo		
3. ¿Se puede disminuir el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional?	Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Se disminuye el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional	Independiente Usar (“si”, “no”) Dependiente Tiempo del diagnóstico precoz usando visión computacional. Tiempo del diagnóstico precoz sin usar visión computacional.	Tiempo. 10 min. Aprox. Y no es invasivo. 60 min. Aprox. Y es invasivo.
Si se puede disminuir	El sistema lo disminuye	Se disminuye el tiempo		

Elaboración: Propia.

CONCLUSIONES Y RECOMENDACIONES

Para concluir este trabajo de tesis, este capítulo se dedicará a mostrar las conclusiones y recomendaciones obtenidas a lo largo del trabajo en este estudio. Lo anterior será con el fin de que se le pueda dar continuidad al estudio que se ha realizado, así como mostrar los beneficios obtenidos.

CONCLUSIONES

1. Luego de revisar diferentes metodologías se determina que para la creación de este tipo de sistemas es aceptable la técnica de prototipado, esta metodología contempla realizar diferentes pruebas y en base a ellas se modifica el prototipo antes de presentar un sistema final. También se estudiaron varios modelos y procesos con diferentes cantidades de imágenes para crear un algoritmo. Estableciendo que las mejores técnicas para el diagnóstico asistido por computadora son: Deep Learning, redes neuronales convolucionales y aprendizaje supervisado. Debido a esto el algoritmo diseñado cumple con un preprocesamiento de imagen que ayuda a las RNC a extraer las más mínimas características de la enfermedad.
2. El objetivo específico 1: “Detección de la retinopatía diabética”, gracias al crowdsourcing se logró obtener más de 88.000 imágenes para clasificar y estudiar el entrenamiento. Se clasificó 12.000 y para el prototipo final se escogió 8.000 por diferentes factores, uno de ellos el desbalanceo de las clases. Además, algunas imágenes estaban en diferentes calidades, tenían mucho ruido como luminosidad, diferente zoom, e incluso estaban mal clasificadas por enfermedad y debido a esto algunos modelos se vieron afectados. Se ha logrado a través del modelo utilizado y las pruebas realizadas, porque podemos afirmar que se tiene una certeza del 80% para la detección de la retinopatía diabética en su etapa temprana, que va a permitir al oftalmólogo sugerir el tratamiento más adecuado para el paciente.
3. El objetivo específico 2: “Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética”, se ha logrado porque podemos afirmar que el costo que demandaría el sistema es menor en comparación a no utilizarlo, hemos demostrado

que los equipos médicos utilizados para este tipo de diagnóstico son muy caros, los precios de los más económicos están entre \$1000 a \$50000.

4. El objetivo específico 3: “Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética”, se ha logrado porque hemos demostrado que, con el sistema, el oftalmólogo solo tendría capturar la imagen y dejar que el sistema detecte la presencia de retinopatía diabética, pero también el tiempo se reduce porque ahora el proceso en su conjunto no es invasivo para el paciente.

RECOMENDACIONES

1. En vista de que existen imágenes mal clasificadas por la enfermedad, se recomienda que el crowdsourcing modifique la base de datos para que sus usuarios tengan información idónea y sin errores. Esto para que el programa no tenga problemas de aprendizaje y mucho menos de predicción. Se aconseja además trabajar en conjunto con clínicas especializada en la detección de la retinopatía para evitar clasificaciones erróneas e intercambiar imágenes en caso de que tengan ruido.
2. El estudio de la Inteligencia Artificial es amplio, por lo que se recomienda seguir indagando metodologías y algoritmos para mejorar la detección de enfermedades a través de imágenes. Se sugiere que se modifique el desempeño de la red, experimentando con capas y neuronas más profundas a fin de optimizar los resultados obtenidos.
3. Es importante que, para estos trabajos se tenga una computadora con tarjetas gráficas de preferencia con denominación Geforce, es decir que tienen unidades de procesamiento gráfico (GPU), para evitar retrasos de aprendizajes. Este trabajo también puede ser utilizados para apoyar otros campos de la medicina. Por lo que se recomienda estudiar este algoritmo y aplicarlo en cualquier tipo de imágenes para detectar o predecir tumores cerebrales, pulmonares, entre miles de enfermedades, en donde la medicina utiliza las imágenes para dar un diagnóstico.
4. Queda como reto considerar este trabajo de investigación para aquellos que deseen implementar el Deep learning y redes neuronales convolucionales en aplicaciones

móviles. En este sentido Google ha presentado su marco de trabajo MLKIT, para el aprendizaje automático, pero se necesita avanzar más incorporando el uso de TensorFlow, donde MLKIT puede ser considerado una capa de API. Finalmente se puede decir que se puede desarrollar una interfaz que haga posible la captura de la imagen de fondo de ojo y esta sea ingresada directamente al sistema, de esta manera el oftalmólogo solo tendría que tomar la fotografía de fondo de ojo y utilizando la interfaz la enviaría al sistema.

REFERENCIAS BIBLIOGRÁFICAS

Alibaba. (2020). Precios de equipos para fondo de ojos. Recuperado de: https://spanish.alibaba.com/promotion/promotion_eye-fundus-camera-promotion-list.html, septiembre 2020.

Alibaba. (2020). Precios de equipos para tratamiento de la retina. Recuperado de: <https://spanish.alibaba.com/g/topcon-oct.html>, septiembre 2020.

Amazon. (2020). Precios de Amazon S3. Recuperado de: <https://aws.amazon.com/es/s3/pricing/>, agosto 2020.

Amol Prataprao Bhatkar, Govind Kharat. (2016). FFT based detection of Diabetic Retinopathy in Fundus Retinal Images.

Anuradha M. Kudatarkar, Netravati R. Sunagar, Poornima S. Sunagar. (2016-17). An intelligent mobile application for determination of spectacle number.

Arisa Ema, Katsue Nagakura, Takanori Fujita. (2020). Proposal for Type Classification for Building Trust in Medical Artificial Intelligence Systems.

Ballard, D.H, Brown, C.M. (1982). Computer Vision. Editorial Prentice Hall.

Behnam Pourghassemi, Chenghao Zhang. (2020). Brief Announcement: On the Limits of Parallelizing Convolutional Neural Networks on GPUs.

Bismedic. (2020). Precios de equipo de fondo de ojos. Recuperado de: <https://es.bimedis.com/zeiss-visuscout-100-m25237>, septiembre 2020.

Bodeetorn Sutcharit, Pakinee Aimmanee, Pongsate Tangseng. (2019). OD Localization Using Rotational 2D Vessel Projection with Decision Tree Classification.

Carta Silvio. (2020). Machine Learning and Computational Design.

CENETEC: Instituto Mexicano del Seguro Social. (2014). Detección de RETINOPATÍA DIABÉTICA en Primer Nivel de Atención. Recuperado de: http://www.cenetec.salud.gob.mx/descargas/gpc/CatalogoMaestro/IMSS-735-14-Deteccion_de_retinopatia_diabetica/735GER.pdf, agosto 2019.

Dunsmore, H. E., Conte, S. D., & Shen, V. (1986). Software engineering metrics and models. Menlo Park.

E_ophtha: is a database of color fundus images especially designed for scientific research in Diabetic Retinopathy (DR). (2013). Recuperado de: <http://www.adcis.net/en/third-party/e-ophtha/>, agosto 2019.

Finley, T. P. (2018). FAQ: Eye examination. Retrieved October 26, 2018, from <https://visionsource-drfinley.net/about-us/frequently-asked-questions/#3>.

Fred Hohman, Kanit Wongsuphasawat, Mary Beth Kery, Kayur Patel. (2020). Understanding and Visualizing Data Iteration in Machine Learning.

García Navarro, B., et al. (2015). Implementación de técnicas de deep learning.

Hernández, S. R., Carlos Fernández Collado, María del Pilar Baptista Lucio. (2014). Metodología de la investigación.

Hospital Cayetano Heredia. (2019). Tarifario en línea. Recuperado de: http://www.hospitalcayetano.gob.pe/PortalWeb/wp-content/uploads/2019/03/TARIFARIO_INSTITUCIONAL_2018_HCH.pdf, septiembre 2020.

Hospital Arzobispo Loayza. (2020). Tarifario institucional. Recuperado de: http://hospitalloayza.gob.pe/MVC_Controlador/IndexC/indexC.php?acc=Transparencia003&tmenu=19&tsubmenu=57, septiembre 2020.

INEI: Instituto Nacional de Estadística e Informática, 2017. El 17,6% de la población de 15 y más años tienen hipertensión arterial. Recuperado de: <https://www.inei.gob.pe/prensa/noticias/el-176-de-la-poblacion-de-15-y-mas-anos-de-edad-tienen-hipertension-arterial-9771/>, junio 2018.

INO: Instituto Nacional de Oftalmología, 2015. Tarifario institucional INO. Recuperado de: <https://es.slideshare.net/liaChavez/tarifario-ino-2015>, agosto 2020.

Iván Ríos Hernández, Edgardo Manuel Felipe Riverón. (2007). Desarrollo de un sistema de análisis de retinas humanas.

Jeroen Klein Brinke, Nirvana Meratnia. (2020). Scaling Activity Recognition Using Channel State Information Through Convolutional Neural Networks and Transfer Learning.

Kusuma Wardhani Mega, Xiangru Yu, Jinping Li. (2018). Comparative Analysis of Color Edge Detection for Image Segmentation.

Libralao G. L, Osvaldo C. P. de Almeida, Antonio Valerio Netto, Alexandre C. B. Delbem, Andre C. P. Leon F. de Carvalho. (n.d.). Artificial Intelligence Technics for Ocular Errors Analysis.

Lookafteryoureyes. (2018). What happens in an eye examination? Retrieved October 25, 2018, from <https://lookafteryoureyes.org/seeing-clearly/the-eye-examination/>

Mayoclinic, 2020. Retinopatía diabética diagnóstico y tratamiento. Recuperado de: <https://www.mayoclinic.org/es-es/diseases-conditions/diabetic-retinopathy/diagnosis-treatment/drc-20371617>, Julio 2020.

Mariakakis A, Shwetak P. (2016). Ocular Symptom Detection using Smartphones. Computer Science & Engineering | DUB Group. University of Washington Seattle. WA 98195 USA.

NIH: National Eyes Institute, 2016. La retinopatía diabética Lo que usted debe saber. Recuperado de: <https://nei.nih.gov/health/espanol/retinopatia>, Julio 2019.

Noushin Eftekhari, Dr. Hamidreza Pourreza, Mojtaba Masoudi, Dr. K. Ghiasi Shirazi and Dr. EhsanSaeedi. (2019). Microaneurysm detection in fundus images using a two-step convolutional neural network. the Creative Commons Attribution 4.0 International License. Recuperado de: <http://creativecommons.org/licenses/by/4.0/>, agosto 2019.

Neera Singh, Atul Kumar, Ramesh Chandra Tripathi. (2010). An Automated Hybrid Technique for Detecting The Stage Of Non-Proliferative Diabetic Retinopathy.

Patrick Henry Winston, Addison-Wesley. (1992). Artificial Intelligence.

Prateek Prasanna, Shubham Jain, Neelakshi Bhagat, Anant Madabhushi. (2013). Decision Support System for Detection of Diabetic Retinopathy Using Smartphones. Department of Electrical and Computer Engineering, Rutgers University, USA. WINLAB, Rutgers University, USA. Institute of Ophthalmology and Visual Science, UMDNJ, USA. Department of Biomedical Engineering, Case Western Reserve University, USA.

Praveen K. Pilly, Nigel D. Stepp, Yannis Liapis, David W. Payton, Narayan Srinivasa. (2020). Hypercolumn Sparsification for Low-Power Convolutional Neural Networks.

Prince S. (2012). Computer vision: models, learning and inference. Recuperado de: <http://web4.cs.ucl.ac.uk/staff/s.prince/book/book.pdf>.

Retamozo Sánchez, M. Á. (n.d.). Predicción de puntos de vista de imágenes 2d usando Deep learning.

Ríos H. I, Edgardo Manuel Felipe Riverón. (2007). Desarrollo de un sistema de análisis de retinas humanas.

Sarni Suhaila Rahim, Chrisina Jayne, Vasile Palade, James Shuttleworth. (2015). Automatic detection of microaneurysms in colour fundus images for diabetic retinopathy screening.

Seyed Jalaleddin Mousavirad, Gerald Schaefer. (2020). A Benchmark of Recent Population-Based Metaheuristic Algorithms for Multi-Layer Neural Network Training.

Sérgio Bortolin Júnior, Daniel Welfer. (2013). Automatic Detection of Microaneurysms and Hemorrhages in color eyes fundus images.

Shamshad Ansari. (2020). Building Computer Vision Applications Using Artificial Neural Networks With Step-by-Step Examples in OpenCV and TensorFlow with Python

Simon Prince. (2012). Computer vision: models, learning and inference. Recuperado de: <http://web4.cs.ucl.ac.uk/staff/s.prince/book/book.pdf>.

Siswo Wardoyo, Anggoro Suryo Pramudyo, Erika Diana Rizanti, Imamul Muttakin. (2016). Exudate and Blood Vessel Feature Extraction in Diabetic Retinopathy Patients using Morphology Operation.

Tamayo, T. M. (2012). El proceso de la Investigación Científica. Mexico: Editorial Limusa.

Tongping Shen, Fangliang Huang, Li Jin. (2019). An Improved Edge Detection Algorithm for Noisy Images.

Vargas Camilo, Qianni Zhang, Ebroul Izquierdo. (2020). One Shot Logo Recognition Based on Siamese Neural Networks.

Winston P. H. (1992). Artificial Intelligence. Boston: Person education.

Zhou Shao, Zhenting Shen, Sha Yuan, Jie Tang, Yongli Wang, Lili Wu, Wenjiang Zheng. (2020). AI 2000: A Decade of Artificial Intelligence.

ANEXOS

ANEXO A: Declaración de autenticidad



Escuela de Posgrado

DECLARACIÓN DE AUTENTICIDAD Y NO PLAGIO

DECLARACIÓN DEL GRADUANDO

Por el presente, el graduando: *(Apellidos y nombres)*

ROBALINO GÓMEZ HERNÁN

en condición de egresado del Programa de Posgrado:

INGENIERÍA INFORMÁTICA CON MENCIÓN EN INGENIERÍA DE SOFTWARE

deja constancia que ha elaborado la tesis intitulada:

DIAGNÓSTICO PRECOZ DE LA RETINOPATÍA DIABÉTICA UTILIZANDO
VISIÓN COMPUTACIONAL

Declara que el presente trabajo de tesis ha sido elaborado por el mismo y no existe plagio/copia de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por cualquier persona natural o jurídica ante cualquier institución académica, de investigación, profesional o similar.

Deja constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no ha asumido como suyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o de la Internet.

Asimismo, ratifica que es plenamente consciente de todo el contenido de la tesis y asume la responsabilidad de cualquier error u omisión en el documento y es consciente de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, el graduando se somete a lo dispuesto en las normas de la Universidad Ricardo Palma y los dispositivos legales vigentes.


Firma del graduando

21 /12 / 2020
Fecha

ANEXO B: Autorización de consentimiento para realizar la investigación



Escuela de Posgrado

AUTORIZACIÓN PARA REALIZAR LA INVESTIGACIÓN

**DECLARACIÓN DEL RESPONSABLE DEL AREA O DEPENDENCIA
DONDE SE REALIZARA LA INVESTIGACIÓN**

Dejo constancia que el área o dependencia que dirijo, ha tomado conocimiento del proyecto de tesis titulado:

DIAGNÓSTICO PRECOZ DE LA RETINOPATÍA DIABÉTICA
UTILIZANDO VISIÓN COMPUTACIONAL.

el mismo que es realizado por el Sr./Srta. Estudiante (Apellidos y nombres):

ROBALINO GÓMEZ HERNÁN

, en condición de estudiante - investigador del Programa de:

INGENIERÍA INFORMÁTICA CON MENCIÓN EN ING. DE SOFTWARE

Así mismo señalamos, que según nuestra normativa interna procederemos con el apoyo al desarrollo del proyecto de investigación, dando las facilidades del caso para aplicación de los instrumentos de recolección de datos.

En razón de lo expresado doy mi consentimiento para el uso de la información y/o la aplicación de los instrumentos de recolección de datos:

Nombre de la empresa: CENTRO MEDICO NAVAL " MARINA DE GUERRA DEL PERU "	Autorización para el uso del nombre de la Empresa en el Informe Final	<input checked="" type="checkbox"/> SI <input type="checkbox"/> NO
---	---	---

Apellidos y Nombres del Jefe/Responsable del área: MIRANDA HIGAR REDY	Cargo del Jefe/Responsable del área: EQUIPAMIENTO MEDICO
--	---

Teléfono fijo (incluyendo anexo) y/o celular: 990203903	Correo electrónico de la empresa: rdy002@gmail.com
--	---

SUPERVISOR AP
ELECTRONICO
REDY MIRANDA HIGAR
05817705
Firma

22/enero/2020
Fecha

MINISTERIO DE DEFENSA
Centro Médico Naval "CMST"
Div. Enseñ. Médico y Eco.
22 ENE 2020
RECIBIDO
Hora: Firma:

ANEXO C: Matriz de consistencia

Planteamiento del Problemas	Objetivos	Hipótesis	Variables	Indicadores
Pregunta General: ¿Se puede mejorar el diagnóstico precoz de la retinopatía diabética?	General: Mejorar el diagnóstico precoz de la retinopatía diabética utilizando visión computacional.	General: El diagnóstico precoz de la retinopatía diabética se mejora con la visión computacional		
Pregunta Específicos:	Específicos:	Específicos:	Independiente Usar (“si”, “no”) Dependiente Retinopatía diabética identificada usando visión computacional. Retinopatía diabética identificada sin usar visión computacional.	Precisión.
4. ¿Se puede detectar la retinopatía diabética usando visión computacional?	Detección de la retinopatía diabética usando visión computacional.	Se mejorar la identificación de la retinopatía diabética usando visión computacional.		
5. ¿Se puede disminuir el costo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional?	Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Se disminuye el costo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional.	Independiente Usar (“si”, “no”) Dependiente Costo del diagnóstico precoz usando visión computacional. Costo del diagnóstico precoz sin usar visión computacional.	Cantidad de dinero que se gasta en la atención.
6. ¿Se puede disminuir el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional?	Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Se disminuye el tiempo del diagnóstico precoz en la identificación de la retinopatía diabética usando visión computacional	Independiente Usar (“si”, “no”) Dependiente Tiempo del diagnóstico precoz usando visión computacional. Tiempo del diagnóstico precoz sin usar visión computacional.	Tiempo de respuesta.

ANEXOS OTROS

Matriz de operacionalización

Objetivo general: Mejorar el diagnóstico precoz de la retinopatía diabética y su tipo utilizando visión computacional				
Objetivos específicos	VARIABLES	DIMENSIÓN	INDICADORES	ÍTEMS
Detección de la retinopatía diabética usando visión computacional.	Visión computacional	Tratamiento de la imagen de fondo de ojo	Precisión.	¿Cuáles son los métodos para el tratamiento de las imágenes de fondo de ojo?
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?
Disminuir el costo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Visión computacional	Accesibilidad económica	Cantidad de dinero que se gasta en la atención	Cantidad de soles
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?
Disminuir el tiempo del diagnóstico precoz para identificar la retinopatía diabética usando visión computacional.	Visión computacional	Tratamiento de la imagen de fondo de ojo	Tiempo de respuesta	Cantidad de minutos.
	Diagnóstico precoz	Anomalía	Retinopatía diabética.	¿Cuáles son las características de la retina diabética?

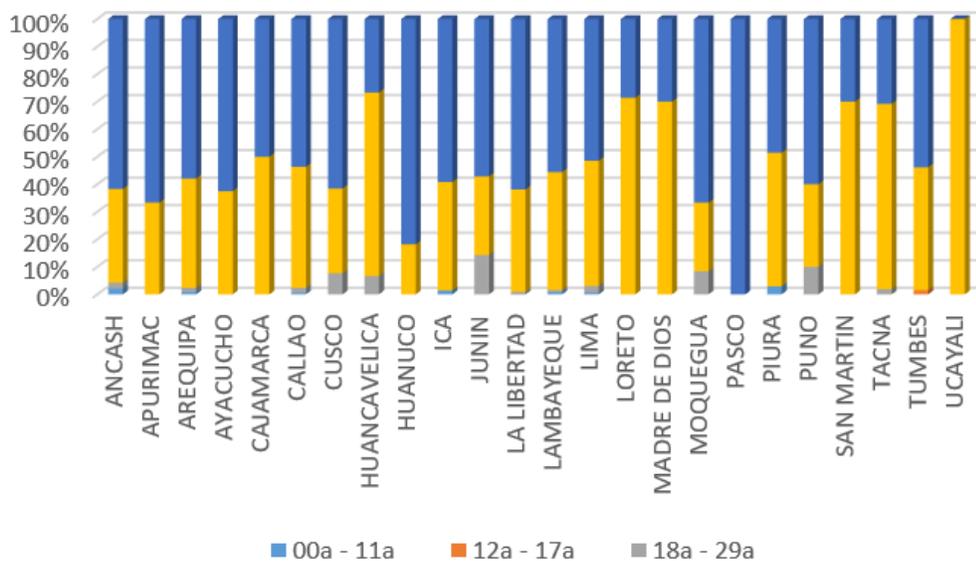
Solicitud de información relacionada a la retinopatía diabética en nuestro país

Ministerio de Salud - Solicitud de Acceso a la Información Pública

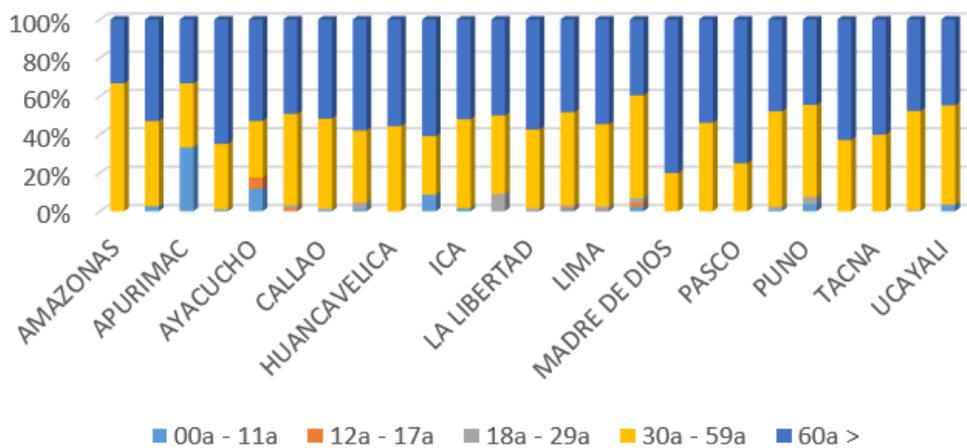
http://www.minsa.gob.pe/portada/transparencia/solicitud/frnFor...

 PERÚ Ministerio de Salud		SOLICITUD DE ACCESO A LA INFORMACIÓN PÚBLICA <small>(Texto Único Ordenado de la Ley Nº 27806, Ley de Transparencia y Acceso a la Información Pública, aprobado por Decreto Supremo Nº 043-2003-PCM)</small>		(*) Datos Obligatorios Nº DE SOLICITUD 18-007738 26/09/2018
FÓRMULARIO				
I. FUNCIONARIO RESPONSABLE DE ENTREGAR LA INFORMACIÓN				
II. DATOS DEL SOLICITANTE				
APellidos y Nombres / Razón Social	ROBALINO GOMEZ HEIRAN *			
Tipo de Documento de Identidad	<input checked="" type="radio"/> D.N.I. <input type="radio"/> L.M. <input type="radio"/> R.U.C. <input type="radio"/> C.E. <input type="radio"/> OTRO			
Documento de Identidad	07221171 *			
Domicilio Av / Calle / Jr / Paj	AV RAFAEL ESCARDO 345 *			
Nº / DPTO. / INT. URBANIZACIÓN	DPTO 201 *			
Departamento	LIMA *			
Provincia	LIMA *			
Distrito	SAN MIGUEL *			
Correo Electrónico	hroba@gmail.com			
Teléfono	99608888			
III. INFORMACIÓN SOLICITADA				
ESTADÍSTICA EN EL PERÚ (POR DEPARTAMENTO) DE LA RETINOPATÍA DIABÉTICA				400 *
IV. DEPENDENCIA DE LA CUAL SE REQUIERE LA INFORMACIÓN				
DESCONOCIDO DEPENDENCIA				<input checked="" type="radio"/> MINSA <input type="radio"/> OTROS
V. FORMA DE ENTREGA DE LA INFORMACIÓN				
<input type="radio"/> COPIA SIMPLE <input type="radio"/> DISKETTE <input type="radio"/> CD <input checked="" type="radio"/> CORREO ELECTRÓNICO <input type="radio"/> OTRO				
VI. OBSERVACIONES				
LA INFORMACIÓN SOLICITADA ME APOYARA EN MI TESIS DE MAESTRÍA				200

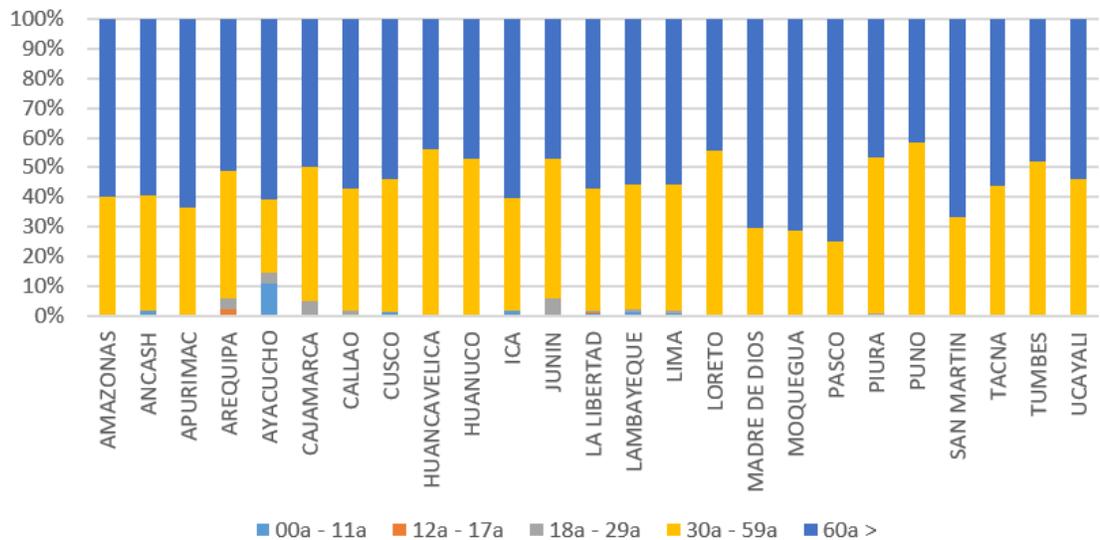
CASOS DE RETINOPATIA DIABETICA POR ETAPAS DE VIDA, SEGÚN DEPARTAMENTOS - AÑO 2014



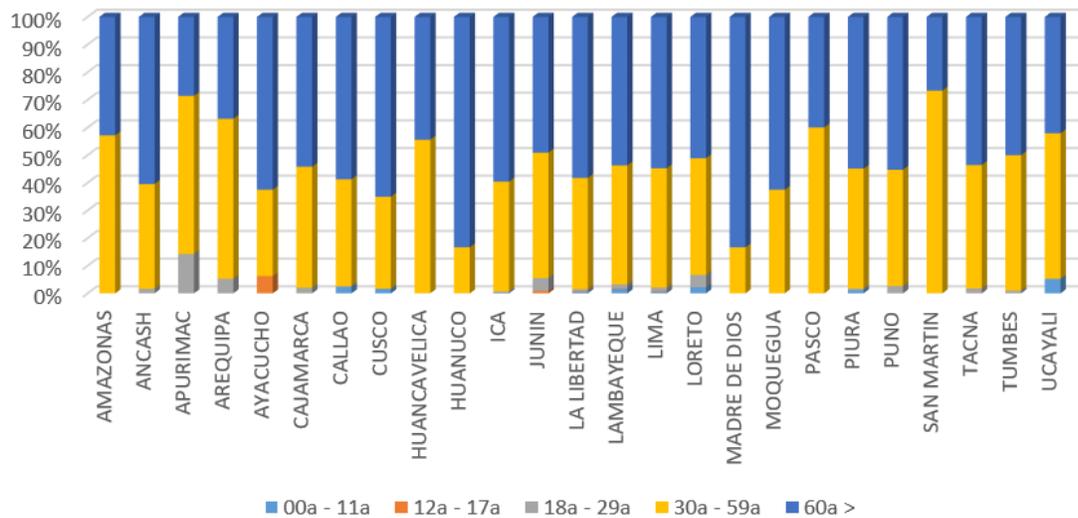
CASOS DE RETINOPATIA DIABETICA POR ETAPAS DE VIDA, SEGÚN DEPARTAMENTOS - AÑO 2015



CASOS DE RETINOPATIA DIABETICA POR ETAPAS DE VIDA, SEGÚN DEPARTAMENTOS - AÑO 2016



CASOS DE RETINOPATIA DIABETICA POR ETAPAS DE VIDA, SEGÚN DEPARTAMENTOS - AÑO 2017



Matemáticas y algoritmo utilizado en la red neuronal convolucional

Preprocesamiento

El código del preprocesamiento de las imágenes se pueden explorar en el siguiente link.

https://docs.google.com/document/d/1thuPAU78ilzHtqZyID_ujiwdccgiSU14j7ELM_PJCSk/edit?usp=sharing

Base de datos

La base de datos que se ha utilizado para realizar nuestra investigación es la que proporciona la empresa Eyepacs en la plataforma Kaggle, en ella se tiene distintas bases de datos que pueden ser utilizadas en minería de datos o investigaciones referentes en machine learning o Deep learning. Ello se puede ubicar en el siguiente link.

<https://www.kaggle.com/hmchuong/lite-eyepacs/data>

Herramientas de programación

Las herramientas para programar y hacer filtros de las imágenes utilizadas en el preprocesamiento es OpenCV. Esta herramienta proporciona un conjunto de diversas funciones establecidas para realizar diversas operaciones con las imágenes. Se puede revisar dichas funciones en el siguiente link.

https://docs.opencv.org/master/d9/df8/tutorial_root.html

Métodos matemáticos

Método matemático de HoughCircles() para detectar círculos. Este método se puede revisar en el siguiente link.

https://docs.opencv.org/2.4/doc/tutorials/imgproc/imgtrans/hough_circle/hough_circle.html

Matemática para el tratamiento de color en las imágenes. Estas matemáticas se pueden revisar en los siguientes links.

https://docs.opencv.org/3.4/de/d25/imgproc_color_conversions.html

https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_filtering/py_filtering.html

Matemática para detectar borde y hacer filtros utilizando el algoritmo de Prewitt. Estas matemáticas se pueden revisar en el siguiente link.

<http://www.boletin.upiita.ipn.mx/index.php/ciencia/669-cyt-numero-55/1293-extraccion-de-bordes-operadores-sobel-prewitt-y-roberts>

Matemática para detectar redimensionar imágenes utilizando el método `resize()`. Estas matemáticas se pueden revisar en el siguiente link.

https://docs.opencv.org/2.4/modules/imgproc/doc/geometric_transformations.html?highlight=resize#cv2.resize

Algoritmos

Paso 1: Recortar la imagen

```
# Importamos las bibliotecas para usar "opencv" y "numpy" en python
```

```
import sys
```

```
import cv2 as cv
```

```
import numpy as np
```

```
# subimos nuestra imagen a trabajar
```

```
image = cv2.imread('URL')
```

```
cv2.imshow('Original', image)
```

```
# Ahora vamos transformar la imagen de colores a escala de grises
```

```
gray = cv.cvtColor(image, cv.COLOR_BGR2GRAY)
```

```
# Vamos a reducir la mitad de la intensidad del gris para que sólo se pueda ver el borde
```

```
gray = cv.medianBlur(gray, 5)
```

```
# Vamos a buscar el círculo y su radio usando el método HoughCircles()
```

```
rows = gray.shape[0]
```

```
circles = cv.HoughCircles(gray, cv.HOUGH_GRADIENT, 1, rows / 8,
```

```

param1=100, param2=30,
minRadius=1, maxRadius=30)

if circles is not None:

circles = np.uint16(np.around(circles))

for i in circles[0, :]:

center = (i[0], i[1])

cv.circle(image, center, 1, (0, 100, 100), 3)

radius = i[2]

cv.circle(image, center, radius, (255, 0, 255), 3)

# Mostramos la figura detectada para obtener el radio y poder cortar la imagen

cv.imshow("Círculos detectados", image)

cv.waitKey(0)

# Buscamos los puntos del borde

retval, thresh_gray = cv2.threshold(image, thresh=100, maxval=255,
type=cv2.THRESH_BINARY)

points = np.argwhere(thresh_gray==0)

points = np.fliplr(points)

x, y, w, h = cv2.boundingRect(points)

#Creamos un nuevo borde de la imagen

x, y, w, h = x-10, y-10, radius+20, radius+20

crop = gray[y:y+h, x:x+w]

retval, thresh_crop = cv2.threshold(crop, thresh=200, maxval=255, type=cv2.THRESH_BINARY)

# Mostramos la figura detectada

cv2.imshow("Imagen recortada", thresh_crop)

```

```
cv2.waitKey(0)
```

Paso 2: Convertir a escala de gris

```
# Importamos las bibliotecas para usar “opencv” y “numpy” en python
```

```
import cv2
```

```
import numpy
```

```
# subimos nuestra imagen a trabajar
```

```
image = cv2.imread('URL')
```

```
cv2.imshow('Original', image)
```

```
# Aplicamos la función “Guassian blur” a la imagen para disminuir al 50% los colores RGB
```

```
dst = cv2.GaussianBlur(image,(5,5),cv2.BORDER_DEFAULT)
```

```
# Mostramos las diferencias entre la imagen original y la imagen con el 50% de color
```

```
cv2.imshow("Gaussian Smoothing",numpy.hstack((image, dst)))
```

```
# Ahora vamos transformar la imagen reducida de colores a escala de grises
```

```
# Utilizamos la función cvtColor para convertir la imagen a escala de grises
```

```
gray_image = cv2.cvtColor(dst, cv2.COLOR_BGR2GRAY)
```

```
#Mostramos la imagen a escala de grises
```

```
cv2.imshow(Escala de grises, gray_image)
```

```
# Ahora vamos a aumentar el contraste
```

```
lab= cv2.cvtColor(gray_image , cv2.COLOR_BGR2LAB)
```

```
cv2.imshow("lab",lab)
```

```
# Dividimos la imagen en canales
```

```
l, a, b = cv2.split(lab)
```

```
cv2.imshow('l_channel', l)
```

```

cv2.imshow('a_channel', a)

cv2.imshow('b_channel', b)

# Aplicamos CLAHE to L-channel

clahe = cv2.createCLAHE(clipLimit=3.0, tileGridSize=(8,8))

cl = clahe.apply(l)

cv2.imshow('CLAHE output', cl)

# Juntamos todo para crear una nueva imagen con el aumento del contraste

limg = cv2.merge((cl,a,b))

cv2.imshow('limg', limg)

# Volvemos a construir la imagen con los colores BGR

final = cv2.cvtColor(limg, cv2.COLOR_LAB2BGR)

cv2.imshow('final', final)

```

Paso 3: Aislamiento de bordes

```

# Importamos las bibliotecas para usar "opencv", "numpy" y "math" en python

from numpy import array

import cv

import numpy as np

import math

#Funcion para sacar la magnitud de gradiente (esto sirve detectar el borde)

def edge_mag(gx,gy,n,m):

    xm = pow(gx,2)

    ym = pow(gy,2)

    g = int(math.sqrt(xm+ym))

```

```

#arr_gra(n,m) = g

if g > 255:

    g = 255 #Si el gradiente es mayor a 255 entonces es blanco

if g < 0: #Si el gradiente es menor a 0 entonces es negro

    g = 0

#arr_bor(n,m) = g #Si es borde valdra 255 si no lo es será 0

# función para correr el código

def main():

    im = cv2.imread('URL')

    im.show()

    arr_gry = array(im)

    (i,j) = (arr_gry.shape[0],arr_gry.shape[1])

    arr_gra = np.zeros(shape = (arr_gry.shape[0],arr_gry.shape[1]))

    arr_bor = np.zeros(shape = (arr_gry.shape[0],arr_gry.shape[1]))

    mask_Prewx = array([(-1,0,1),(-1,0,1),(-1,0,1)])

    mask_Prewy = array([(1,1,1),(0,0,0),(-1,-1,-1)])

    a = arr_gry

    n = 1

    m = 1

    for n in range(i-1): #Barremos por filas

        for m in range(j-1): #Barremos por columnas

            p_z_9 = array([(a[n-1,m-1],a[n-1,m],a[n-1,m+1]),(a[n,m-1],a[n,m],a[n,m+1]),(a[n+1,m-1],a[n+1,m],a[n+1,m+1])])

            gx = np.sum(p_z_9*mask_Prewx)

```

```

gy = np.sum(p_z_9*mask_Prewy)

xm = pow(gx,2)

ym = pow(gy,2)

g = int(math.sqrt(xm+ym))

if g > 135: #Este numero sirve de umbral para quitar ruido

    g = 255 #Si el gradiente es mayor a 255 entonces es blanco

elif g < 0: #Si el gradiente es menor a 0 entonces es negro

    g = 0

else: #Este tambien sirve para quitar ruido

    g = 0

arr_bor[n,m] = g

cv.SaveImage("figura_sin_borde.png",cv.fromarray(arr_bor))

im_b = Image.open('figura_sin_borde.png')

im_b.show()

```

Paso 4: Aislamiento de bordes

```

# Importamos las bibliotecas para usar "opencv"

import cv2

# subimos nuestra imagen a trabajar

image = cv2.imread('URL')

cv2.imshow('Original', image.shape)

width = 512

height = 512

dim = (width, height)

```

```
# Función para redimensionar el tamaño de la imagen con el método resize()
resized = cv2.resize(image, dim, interpolation = cv2.INTER_AREA)
cv2.imshow("Resized image", resized)
cv2.waitKey(0)
cv2.destroyAllWindows()
```