



Universidad Autónoma de Querétaro
Facultad de Ingeniería

Aprendizaje máquina en la determinación de factores para el diagnóstico de retinopatía diabética y otras enfermedades oculares.

Tesis

Que como parte de los requisitos para el obtener el Grado de Maestro en Ciencias en Inteligencia Artificial

Presenta:

María Fernanda Cisneros Guzmán

Dirigido por:

Dr. Saúl Tovar Arriaga

Querétaro, Qro. a 04 de Noviembre de 2019.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
Facultad de Ingeniería
Maestría en Ciencias en Inteligencia Artificial

Aprendizaje máquina en la determinación de factores para el diagnóstico de
retinopatía diabética y otras enfermedades oculares.

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestro en Ciencias en Inteligencia Artificial

Presenta:

María Fernanda Cisneros Guzmán

Dirigido por:

Dr. Saúl Tovar Arriaga

Dr. Saúl Tovar Arriaga

Presidente

Dr. Jesús Carlos Pedraza

Secretario

Dr. Juan Manuel Arreguín Ramos

Vocal

Dr. Arturo González Gutiérrez

Suplente

Mtro. Alejandro de León Cuevas

Suplente

Centro Universitario, Querétaro, Qro.

Fecha de Aprobación

México

ÍNDICE

I. AGRADECIMIENTO.....	1
II. ABREVIATURAS.....	2
III. RESUMEN.....	3
IV. ABSTRACT	4
V. INTRODUCCIÓN.....	5
5.1 Inteligencia Artificial	5
5.2 Clasificación del Aprendizaje Automático	6
5.3 Diabetes	8
5.3.1 Diabetes tipo 1	8
5.3.2 Diabetes tipo 2	9
5.3.3 Diabetes Gestacional	9
5.3.4 Deterioro de la tolerancia a la glucosa y alteración de la glicemia en ayunas.....	10
5.4 Retinopatía Diabética	10
5.5 Diagnóstico Automatizado	15
VI. PLANTEAMIENTO DEL PROBLEMA	19
VII. JUSTIFICACIÓN	20
VIII. HIPÓTESIS	21
IX. OBJETIVOS	21
9.1 Objetivo General.....	21
9.2 Objetivos Específicos	21
X. ANTECEDENTES	22

XI. FUNDAMENTACIÓN TEÓRICA	30
11.1 Procesamiento de imágenes	30
11.2 Espacio de Color	30
11.2 Segmentación de imágenes	33
11.2.1 Operaciones Morfológicas.....	33
11.2.2 Erosión	33
11.2.3 Dilatación.....	34
11.2.4 Apertura.....	35
11.3 Máquina de Vectores de Soporte (SVM)	35
XII. METODOLOGÍA	44
12.1 Base de datos.....	44
12.2 Experimentación	45
12.2.1 Exudados	48
12.2.2 Máscara de Disco óptico	49
12.2.3 Vasos Sanguíneos	50
XIII. RESULTADOS.....	54
XIV. CONCLUSIÓN	57
XV. REFERENCIAS.....	59
XVI. ANEXOS	64
16.1 Carta de Aceptación de artículo a Congreso Internacional.....	64
16.2 Constancia de Participación CoICACI 2019	65
16.3 Artículo.....	66
16.4 Constantia de Acreditación de Lengua	71

ÍNDICE DE FIGURAS

Fig. 1 Sistemas de Inteligencia Artificial.....	5
Fig. 2 Clasificación del Aprendizaje Automático	7
Fig. 3 Partes del ojo	11
Fig. 4. Prueba de Espacios de Color en Imágenes de Retina	46
Fig. 5. Metodología	47
Fig. 6 Exudados Duros	49
Fig. 7 Máscara de Disco Óptico.....	50
Fig. 8 Vasos Sanguíneos.....	51
Fig. 9 Curva ROC	55

ÍNDICE DE TABLAS

Tabla 1. Lesiones de la Retinopatía Diabética.....	12
Tabla 2. Clasificación Escocesa de RD (Zachariah et al., 2015)	15
Tabla 3. Empresas de Diagnóstico Automatizado.	18
Tabla 4. Estado del Arte	28
Tabla 5. Espacios de Color.....	31
Tabla 6. Resultados	56

I. AGRADECIMIENTO

Me gustaría agradecer en las siguientes líneas a todas aquellas personas involucradas a lo largo de estos dos años que me apoyaron en la culminación del presente trabajo.

Primeramente, agradecer a mis padres Lorena Guzmán Martínez y Fernando Cisneros Alonso que me acompañaron a lo largo de este camino y siempre me han guiado y apoyado en mi crecimiento académico, pero sobre en mi crecimiento personal permitiendo llegar a este logro.

Gracias al Dr. Saúl Tovar Arriaga, director de tesis de la investigación presentada, por creer en la propuesta realizada y aceptarme como asesorada, por orientarme y supervisarme durante el desarrollo de dicha investigación, pero sobre todo por el gran apoyo realizado en estos años tanto académicamente como en lo personal.

De igual forma le agradezco a CONACYT y a la UAQ por el apoyo brindado para realizar esta tesis.

II. ABREVIATURAS

DM – Diabetes Mellitus

RD – Diabetic Retinopathy / Retinopatía Diabética

IA – Artificial Intelligence / Inteligencia Artificial

ML – Machine Learning / Aprendizaje Automático

DL – Deep Learning / Aprendizaje Profundo

AS – Supervised Learning / Aprendizaje Supervisado

SVM – Support Vector Machine / Máquina de Vectores de Soporte

RGB – Red, Green, Blue / Rojo, Verde, Azul

CMY – Cyan, Magenta, Yellow / Cian, Magenta, Amarillo

HSI – Hue, Saturation, Intensidad

III. RESUMEN

La retinopatía diabética (RD) es un padecimiento ocular muy común en pacientes diabéticos que se desarrolla cuando se tienen niveles de azúcar altos en sangre, lo que provoca daño en los vasos sanguíneos de la retina. El diagnóstico de RD se basa en detectar diferentes características que se presentan en la parte posterior del ojo, entre los que se encuentra micro-aneurismas, grosor de las venas, hemorragias y exudados. En este trabajo de tesis se propone la detección de exudados y segmentación de vasos sanguíneos, mediante el procesamiento digital de imágenes de la retina para ayudar en la detección de retinopatía.

El objetivo principal es clasificar automáticamente las imágenes en dos categorías, las que presentan exudados y las que no, para de esta forma coadyuvar a la elaboración un informe de retinopatía diabética proliferativa. En una etapa inicial, las características deseadas se realizan vía segmentación para posteriormente ser insertadas en un clasificador basado en máquina de soporte de vectores (SVM) para determinar la existencia de exudados. Esta propuesta se probó en una base de datos de 130 imágenes. Como resultado se obtuvo una sensibilidad del 87.3% y una especificidad del 84.6%.

A pesar de que el desarrollo de la propuesta está enfocado para ayudar en la detección de retinopatía diabética, se ha encontrado que también puede ser utilizado para el diagnóstico y progresión del edema macular.

Palabras Clave: Retinopatía diabética, máquina de soporte de vectores, diagnóstico automatizado, procesamiento de imágenes.

IV. ABSTRACT

Diabetic retinopathy (RD) is a very common eye condition in diabetic patients that develops when they have high blood sugar levels, which causes damage to the blood vessels of the retina. The diagnosis of RD is based on detecting different characteristics that occur in the back of the eye, among which is micro-aneurysms, thickness of the veins, hemorrhages and exudates. This thesis work proposes the detection of exudates and blood vessel segmentation, through digital image processing of the retina to aid in the detection of retinopathy.

The main objective is to automatically classify the images into two categories, those that present exudates and those that do not, to contribute to the elaboration of a report of proliferative diabetic retinopathy. In an initial stage, the desired characteristics are performed via segmentation to later be inserted into a classifier based on vector support machine (SVM) to determine the existence of exudates. This proposal was tested in a database of 130 images. As a result, a sensitivity of 87.3% and a specificity of 84.6% were obtained.

Although the development of the proposal is focused to help in the detection of diabetic retinopathy, it has been found that it can also be used for the diagnosis and progression of macular edema.

Keywords: *Diabetic retinopathy, vector support machine, automated diagnosis, image processing.*

V. INTRODUCCIÓN

5.1 Inteligencia Artificial

Marvin Minsky, matemático pionero y padre del campo de la inteligencia artificial, definió la Inteligencia Artificial como: “La Inteligencia Artificial es la ciencia de construir máquinas para que hagan cosas que, si las hicieran los humanos, requerirían “inteligencia” (Pedrycz, Sillitti, & Succi, 2016). A partir de esta definición, se puede decir que la IA es un sistema informático entrenado para percibir su entorno y tomar decisiones. En la Fig. 1 se ilustran los sistemas de inteligencia artificial que se construyen a partir de algoritmos de aprendizaje, como lo son el *Aprendizaje Automático* y el *Aprendizaje Profundo*.

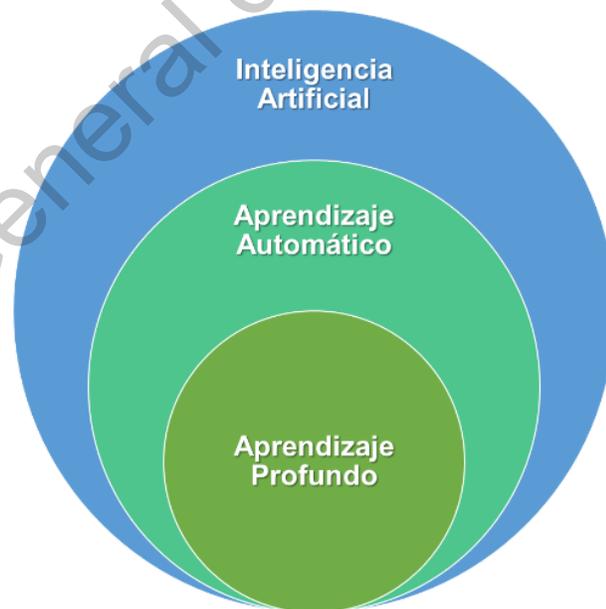


Fig. 1 Sistemas de Inteligencia Artificial

El Aprendizaje Automático (AA) aprende a partir de la experiencia, es decir, enseña a las computadoras a hacer lo que es natural para los humanos y los animales. Los algoritmos de AA utilizan métodos computacionales para "aprender" a partir de la información directa de los datos recolectados, selecciona manualmente las funciones y luego entrena el modelo. Los algoritmos mejoran su rendimiento de forma adaptativa a medida que aumenta el número de muestras disponibles para el aprendizaje. Las técnicas comunes de AA incluyen árboles de decisión, máquinas de vectores de soporte y métodos de conjunto (Fogel, Liu, & Keller, 2016).

5.2 Clasificación del Aprendizaje Automático

La Fig. 2 muestra la existencia de dos técnicas utilizadas en el Aprendizaje Automático. El primero es el Aprendizaje Supervisado (AS), el cual su modelo se entrena a partir de datos de entrada conocidos y así predecir resultados futuros. El AS utiliza técnicas de clasificación y regresión para desarrollar modelos predictivos. Las técnicas utilizadas en el AS incluyen la clasificación (los modelos de clasificación predicen respuestas discretas) y regresión (las técnicas de regresión predicen respuestas continuas).

El segundo se conoce como Aprendizaje No Supervisado (ANS) en este a partir de los datos que se tienen de entrada se buscan estructuras intrínsecas o patrones ocultos (goleman, daniel; boyatzis, Richard; Mckee, 2019). Generalmente es utilizado extraer inferencias de conjuntos de datos que consisten en datos de entrada sin respuestas etiquetadas.



Fig. 2 Clasificación del Aprendizaje Automático

El Aprendizaje Profundo (AP) generalmente se implementa utilizando una arquitectura de red neuronal. Se considera al AP dentro del AA, como se muestra en la Fig. 1, debido a que este utiliza algoritmos clásicos para su entrenamiento. En este tipo de aprendizaje el modelo aprende a realizar tareas de clasificación directamente a partir de imágenes, texto o sonido.

La palabra 'Profundo' hace referencia a las múltiples capas entre las de entrada y salida. Las redes neuronales tradicionales contienen solo 2 o 3 capas, mientras que las redes profundas pueden tener cientos (Fogel et al., 2016). En el AP, el algoritmo aprende automáticamente características que son útiles. Las técnicas comunes de aprendizaje profundo incluyen redes neuronales convolucionales (CNN) y redes neuronales profundas, recurrentes y redes de base radial.

5.3 Diabetes

La permanencia de la diabetes en los países cuyos ingresos son mediano y bajos la diabetes ha aumentado con mayor rapidez. Esta enfermedad es una importante causa de ceguera, insuficiencia renal, infarto de miocardio, accidente cerebrovascular y amputación de los miembros inferiores (De Postura et al., n.d.).

La diabetes es una enfermedad crónica que aparece cuando el organismo no utiliza eficazmente la insulina que produce o cuando el páncreas no produce insulina suficiente. La insulina es una hormona que regula el azúcar en la sangre. El efecto de la diabetes no controlada es la hiperglucemia (aumento del azúcar en la sangre), que con el tiempo daña gravemente muchos órganos y sistemas, especialmente los nervios y los vasos sanguíneos.

Según datos recolectados por la Organización Mundial de la Salud (OMS) en 2014, el 8,5% de los adultos (18 años o mayores) tenía diabetes (Rojas-Martínez et al., 2018). En 2015 fallecieron 1,6 millones de personas como consecuencia directa de la diabetes y los niveles altos de glucemia fueron la causa de otros 2,2 millones de muertes en 2012.

5.3.1 Diabetes tipo 1

La diabetes de tipo 1 (también llamada insulino dependiente, juvenil o de inicio en la infancia) se caracteriza por una producción deficiente de insulina y requiere la administración diaria de esta hormona. Se desconoce aún la causa de la diabetes de tipo 1 y no se puede prevenir con el conocimiento actual.

Sus síntomas consisten, entre otros, en excreción excesiva de orina (poliuria), sed (polidipsia), hambre constante (polifagia), pérdida de peso, trastornos visuales y cansancio. Estos síntomas pueden aparecer de forma súbita.

5.3.2 Diabetes tipo 2

La diabetes de tipo 2 (también llamada no insulino dependiente o de inicio en la edad adulta) se debe a una utilización ineficaz de la insulina. Este tipo representa la mayoría de los casos mundiales y se debe en gran medida a un peso corporal excesivo y a la inactividad física (Espinoza Diaz et al., 2018).

Los síntomas pueden ser similares a los de la diabetes de tipo 1, pero a menudo menos intensos. En consecuencia, la enfermedad puede diagnosticarse solo cuando ya tiene varios años de evolución y han aparecido complicaciones. Hasta hace poco, este tipo de diabetes solo se observaba en adultos, pero en la actualidad también se está manifestando en niños.

5.3.3 Diabetes Gestacional

La diabetes gestacional se caracteriza por hiperglucemia que aparece durante el embarazo y alcanza valores que, pese a ser superiores a los normales, son inferiores a los establecidos para diagnosticar una diabetes. Las mujeres con diabetes gestacional corren mayor riesgo de sufrir complicaciones durante el embarazo y el parto. Además, tanto ellas como sus hijos corren mayor riesgo de padecer diabetes de tipo 2 en el futuro (Rojas-Martínez et al., 2018).

Suele diagnosticarse mediante las pruebas prenatales, más que porque el paciente refiera síntomas.

5.3.4 Deterioro de la tolerancia a la glucosa y alteración de la glicemia en ayunas.

El deterioro de la tolerancia a la glucosa y la alteración de la glicemia en ayunas son estados de transición entre la normalidad y la diabetes, y quienes los sufren corren mayor riesgo de progresar hacia la diabetes de tipo 2, aunque esto no es inevitable.

5.4 Retinopatía Diabética

La Retinopatía Diabética (RD) es una complicación visual, crónica y específica de la diabetes, tiene una prevalencia del 43.6% a nivel internacional, y en México se estima una prevalencia del 31.5% de acuerdo con la Federación Mexicana de Diabetes A.C. ("Estadísticas en México - Federación Mexicana de Diabetes," n.d.)

La Retinopatía Diabética es una complicación de la diabetes y una de las causas principales de la ceguera. Ocurre cuando la diabetes daña a los pequeños vasos sanguíneos de la retina, que es el tejido sensible a la luz situado en la parte posterior del ojo. Es una enfermedad progresiva y asintomática hasta las últimas etapas, que resulta de una lesión vascular con aumento de la permeabilidad y daño capilar (Mistry, Vikhe, & Kadu, 2015). La RD es la tercera causa de ceguera irreversible en el mundo, pero la primera en personas de edad productiva (16 a 64 años) en países en vías de desarrollo, como lo es México.

La Fig. 3 muestra las partes del ojo más importantes las cuales se identifican a partir de una imagen de la parte posterior del ojo, es decir, de la retina. La retina es una capa delgada de tejido que recubre la parte posterior del ojo por dentro. Se encuentra cerca del nervio óptico. El propósito de la retina es recibir la luz que la lente ha enfocado, convertir la luz en señales neuronales y enviar estas señales al cerebro para su reconocimiento visual (Kumar, Pt, & Madhuri, 2016).

Debido al papel vital de la retina en la visión, su daño puede causar ceguera permanente. Las condiciones como el desprendimiento de retina, donde la retina se separa de forma anormal de su posición habitual, pueden evitar que la retina reciba o procese la luz. Esto evita que el cerebro reciba esta información, lo que lleva a la ceguera.

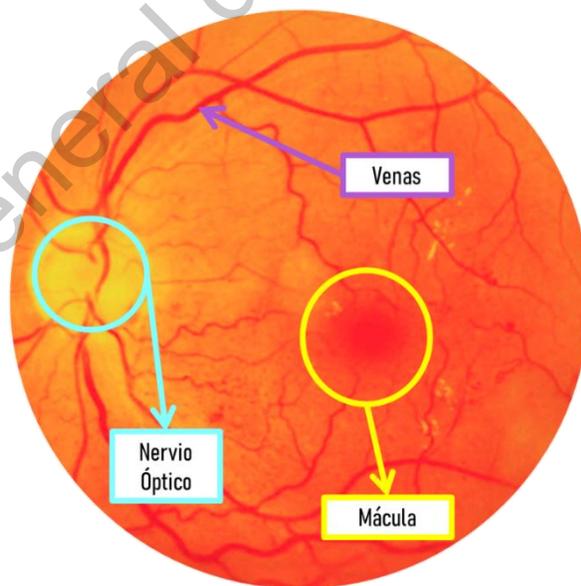


Fig. 3 Partes del ojo

En la mayoría de los países industrializados se ha convertido la RD en la principal causa de pérdida de visión y ceguera entre los adultos. Esta condición es de origen vascular y se caracteriza por signos de isquemia retiniana (microaneurismas, hemorragias, exudados, anomalías microvasculares intrarretinianas, anomalías en el calibre venoso y neovascularización). (Student, Landran, & Kaur, 2015) En la Tabla 1 se muestran las lesiones mencionadas, así como una pequeña descripción de cada una.

Tabla 1. Lesiones de la Retinopatía Diabética

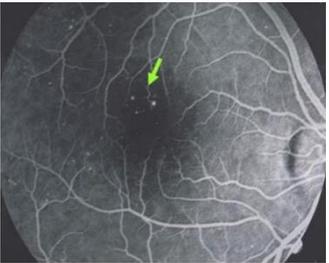
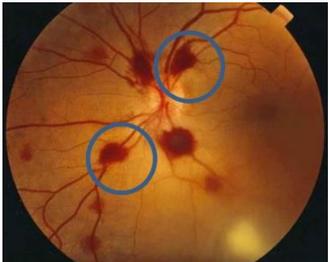
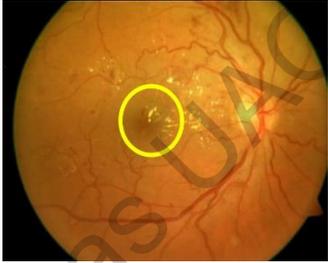
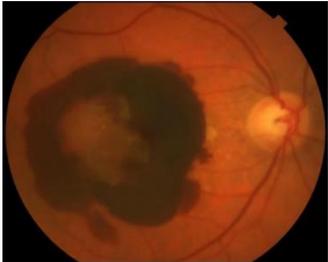
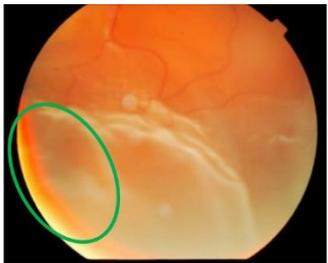
Nombre	Descripción	Descripción gráfica
Microaneurismas	Pequeñas protuberancias en los vasos sanguíneos de la retina que con frecuencia dejan escapar líquido (Lazar & Hajdu, 2013).	
Hemorragias de la retina	Pequeñas manchas de sangre que entran a la retina (Karnowski et al., 2010).	

Tabla 1. Lesiones de la Retinopatía diabética (Continuación)

Exudados	<p>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 (Zachariah, Wykes, & Yorston, 2015).</p>	
Hemorragia vítrea	<p>Hemorragia muy grande que puede bloquear la visión, permitiendo 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 (Rocha, Carvalho, Jelinek, Goldenstein, & Wainer, 2012).</p>	
Desprendimiento de la retina por tracción	<p>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. (Rocha et al., 2012)</p>	

La diabetes mellitus (DM) es una enfermedad degenerativa crónica con una prevalencia mundial del 2-6%. Según la Organización Mundial de la Salud, se estima que actualmente hay 150 millones de personas con diabetes y para 2025 este número se duplicará. Más del 90% de los casos nuevos serán pacientes con diabetes mellitus tipo 2 (DM2), y en México más de la mitad de estos casos no son diagnosticados. El 10% de la población general sufre de DM, que es 3-4% más alta que la reportada en otros países.

El principal problema con DM es la aparición de complicaciones metabólicas, vasculares y neurológicas. La retinopatía diabética (RD) es una de las complicaciones más graves de DM (Deepak & Sivaswamy, 2012); En la mayoría de los países industrializados se ha convertido en la principal causa de pérdida de visión y ceguera entre los adultos. Esta condición es de origen vascular y se caracteriza por signos de isquemia retiniana (microaneurismas, hemorragias, exudados, anomalías microvasculares intrarretinianas, anomalías en el calibre venoso y neovascularización) (Tabla de lesiones), así como signos de aumento de la permeabilidad vascular.

Esto progresa de una enfermedad no proliferativa leve, a una retinopatía no proliferativa moderada o grave, y finalmente a una enfermedad proliferativa, en la Tabla 2 se ilustra la clasificación escocesa de la RD, que permite otorgar un grado de RD a partir de las lesiones presentados. Esta clasificación engloba desde un ojo sano hasta donde los hallazgos oftalmológicos severos están asignados al grado mayor, la RD proliferativa.

Tabla 2. Clasificación Escocesa de RD (Zachariah et al., 2015)

Grado de retinopatía diabética	Hallazgos oftalmológicos
RD Ausente	No hay anomalías
RD No proliferativa	Micro aneurismas
RD No proliferativa moderada	Micro aneurismas Hemorragias
RD No proliferativa severa	Hemorragias intra-retinianas Cuentas venosas definidas Anomalías microvasculares intra-retinianas Exudados
RD Proliferativa	RD no proliferativa severa y 1 o más de los siguientes: Neovascularización Hemorragia vítrea/pre-retiniana

5.5 Diagnóstico Automatizado

La IA está tomando una fuerza inmensa en todas las áreas de investigación. Ya que el manejo de grandes volúmenes de datos nos ha llevado a la implementación de estas técnicas como AA, AP, entre otras más técnicas en zonas donde tiempo atrás era impensable una aplicación de este estilo. A continuación, se enlistan algunos trabajos realizados con IA en diversas áreas de trabajo.

En economía, comercio y educación. se han realizado diversos trabajos como la selección de segmentos en países con bajo presupuesto para un equipo de manufactura basado en un sistema de soporte de (De Postura et al., n.d.). También

se ha utilizado esta misma técnica en la optimización de portafolios para una organización financiera e inversores individuales. (Dong, Du, Wang, Chen, & Deng, 2004) Lo cual vuelve muy interesante el enfoque que se le puede dar a dichas técnicas como por ejemplo también en el área médica, para ser más específicos en odontología, creando un sistema de aprendizaje que ayude a los estudiantes a entender los modelos adaptativos que se utilizan en esta rama de la medicina (Gascuña, Fernández-caballero, & González, n.d.).

En el área de informática y manejo de datos es más que notable la presencia de algoritmos de IA en la resolución de problemas cotidianos como por ejemplo el spam en los servicios de correo electrónico, o incluso el análisis de nuevo malware, el entendimiento del funcionamiento y la prevención de ataques que pueden ocurrir a servidores o computadores domésticos (Rajpurkar et al., 2017).

En la robótica como en la planeación de trayectorias se han realizado un sinnúmero de investigaciones que prueban el buen funcionamiento de las IA, como es el caso de control de robots utilizando técnicas como lógica (Kalisiak & De Van Panne, 2001), o también técnicas como agentes con biorretroalimentación [Biofeedback Agents for Electromyoccontrolled teleoperated Robots]. Y en la planeación de rutas no necesariamente tiene que ser aplicado al mundo real, se puede implementar en caracterización animada [Planning motion for animated characters].

Los problemas que se intentan resolver por medio de técnicas de IA por lo regular son poco habituales que se lleven a una aplicación comercializable ya que por lo general se quedan en solo investigación, pero no quiere decir que no existan empresas que se dediquen a diseñar herramientas de automatización de este estilo. Son pocas y pequeñas, pero están creciendo a pasos agigantados. Al principio se

puede dudar de la fiabilidad de estas técnicas ya que la aparición en el mercado empieza con empresas grandes y ya posteriormente se estandariza para el uso de pequeñas y medianas empresas.

En este trabajo se implementó el algoritmo SVM a la clasificación de imágenes médicas, para ser más específicos a la RD. La detección de patrones en imágenes médicas es un área muy amplia ya que existen diversas enfermedades que se pueden categorizar, ya sean con imágenes RGB para la detección de cáncer (Dabeer, Khan, & Islam, 2019) o imágenes de rayos-X para la búsqueda de pulmonía (Rajpurkar et al., 2017).

Algunas empresas ya comercializan software para la automatización de diagnósticos. También algunas se dedican a la creación de aplicaciones especializadas para resolver problemas específicos que sus clientes requieran, claro si es que esta en las posibilidades de dichas empresas. En la tabla se mencionan algunas de estas empresas, así como la actividad principal que desempeñan.

Tabla 3. Empresas de Diagnóstico Automatizado.

Empresa	Descripción
Aidence	Se especializa en el diagnóstico y visualización de resultados en radiografías. Su principal propósito es la automatización y mejora de lectura para todos aquellos que requieran optimizar sus diagnósticos relacionados con radiografías. Pero también brinda ayuda a hospitales y científicos con un software intuitivo en el análisis de imágenes médicas.
MetaOptima	Dedicada al tratamiento de datos dermatológicos y análisis de la piel. Con la misión de facilitar y mejorar el cuidado de la piel para cualquier persona. El software está dedicado a médicos y a pacientes con dos versiones disponibles. Esta aplicación necesita aditamentos de hardware extras. Con un análisis en la nube.
Diagnostics.ia	Es una empresa que se dedica a crear software automatizado para optimizar el proceso de diagnóstico médico. Presume de tener buenos resultados en sus proyectos realizados, utilizando IA en todos sus proyectos que comenzaron en el año 2014.

VI. PLANTEAMIENTO DEL PROBLEMA

Desde el año 2000, la diabetes mellitus en México es la primera causa de muerte entre las mujeres y la segunda entre los hombres. En 2010, esta enfermedad causó cerca de 83,000 muertes en el país. De acuerdo con la Federación Mexicana de Diabetes A.C. La Retinopatía Diabética es una complicación visual, crónica y específica de la diabetes, tiene una prevalencia del 43.6% a nivel internacional, y en México se estima una prevalencia del 31.5%. En México 3 de cada 10 personas con diabetes padecen esta enfermedad. La retinopatía diabética es prevenible en un 80% de los casos cuando se detecta a tiempo, según la Asociación Mexicana de Retina.

El primer factor de riesgo para la aparición de este problema visual es padecer Diabetes Mellitus de forma prolongada en el tiempo. El segundo factor de riesgo es el mal control metabólico, muy importante para el desarrollo y progresión de la enfermedad. A peor control, la retinopatía aparece a una edad más temprana y con un grado de severidad mayor. Un tercer factor en el diagnóstico temprano para esta enfermedad radica en la falta de información sobre las causas, consecuencias y actividades que prevengan llegar a este punto.

Es importante mencionar que, una vez detectada la enfermedad, la saturación en los servicios médicos públicos, así como la falta de centros oftalmológicos que lleven un seguimiento adecuado en la detección y evolución de la enfermedad dificultan el recibir una atención de la enfermedad. Debido a esta situación se busca la aplicación de una técnica de inteligencia artificial para un diagnóstico temprano de dicha enfermedad.

VII. JUSTIFICACIÓN

La detección de la retinopatía diabética requiere acudir a chequeos frecuentes realizados por un experto en el área, oftalmólogo, así como la realización de estudios costosos, a los cuales no toda la población tiene acceso debido a su costo económico o por el escaso acceso a estas especialidades que los servicios de la salud públicos otorgan a la población en general.

La presente investigación busca el beneficio de la sociedad que cuenta con diabetes diagnosticada, para una detección temprana de una posible retinopatía diabética que pueda presentar. Esto beneficiaría en gran medida a las personas diabéticas debido a los altos índices de ceguera que hay en la población mexicana derivada de las afectaciones que provoca dicha enfermedad. El algoritmo forma parte de un sistema de diagnóstico de la retinopatía que busca ser colocado al alcance de cualquier usuario.

En este trabajo de investigación se emplean técnicas de Aprendizaje Automático en las cuales no es necesario contar un gran número de imágenes y que al mismo tiempo pueden ofrecer un excelente grado de reconocimiento. Así mismo, las bases de datos disponibles son suficientes para realizar un buen entrenamiento.

VIII. HIPÓTESIS

Es posible crear un algoritmo que permita realizar la búsqueda de patrones oculares que faciliten el diagnóstico temprano de retinopatía diabética y otras enfermedades.

IX. OBJETIVOS

9.1 Objetivo General

Crear un algoritmo que permita realizar de un informe que contenga patrones en la retina por medio de imágenes.

9.2 Objetivos Específicos

- Contribuir a la investigación de la detección temprana de la enfermedad ocular “retinopatía diabética”. A partir de las imágenes oculares obtenidas se analizarán patrones pertenecientes a la enfermedad mencionada, mediante técnicas de inteligencia artificial.
- Brindar una herramienta que permita, su aplicación y servir en futuras investigaciones de diversas enfermedades oftalmológicas. Además de ser un recurso real y propio de la universidad el cual puede ser usado como material didáctico en diversas asignaturas que enriquezca la formación académica de los estudiantes.
- Comenzar una clasificación de imágenes de acuerdo con patrones encontrados para comenzar la realización de una base de datos.

X. ANTECEDENTES

Se han realizado varios esfuerzos en la detección automática de RD. Sin embargo, en esta investigación se presentan ejemplos significativos más recientes basados en Aprendizaje Automático (ML), sin tomar en cuenta las contribuciones realizadas con Aprendizaje Profundo (DL). A pesar de que los avances en DL han sido muy importantes, este tipo de aprendizaje requiere de bases de datos muy amplias que deben estar etiquetadas de manera adecuada.

La investigación en los últimos años enfatiza la aplicación de técnicas computacionales en el campo de la oftalmología. Se han realizado investigaciones para la detección de la retinopatía diabética utilizando métodos de inteligencia artificial (IA), tales como aprendizaje profundo y Máquina de Vectores de Soporte (SVM), entre otros métodos de IA. Estos estudios han demostrado ser un buen camino para la detección de anomalías en la retina, con un gran porcentaje de certeza.

En 2005 Zhang aplicó la técnica de Máquina de Vectores de Soporte (SVM) para la detección de aneurismas y micro-venas mediante imágenes obteniendo una especificidad del 89.1% en la detección de los patrones de búsqueda de las imágenes. Para 2009 Osare con una base de 300 imágenes, dividiéndola en dos conjuntos de imágenes, la mitad para entrenamiento y la otra mitad como validación, realizó una combinación de cuatro métodos FCMs, Filtros Gabor, algoritmos genéticos y redes neuronales, para la detección de la enfermedad y obteniendo un 93.50% de especificidad (Zhang & Chutatape, 2005).

En 2012 Deepak se centró en la detección del Edema Macular Diabético (EMD), este es una complicación frecuente de la retinopatía diabética que amenaza la visión. Propone una metodología de dos etapas para la detección y clasificación de la gravedad de EMD a partir de imágenes de fondo de color. La detección de EMD se lleva a cabo a través de un enfoque de aprendizaje supervisado utilizando las imágenes normales del fondo de ojo. Se introduce una técnica de extracción de características para capturar las características globales de las imágenes del fondo y discriminar las imágenes normales de las imágenes EMD. El rendimiento de detección tiene una exactitud del 81%. (Deepak & Sivaswamy, 2012)

Por su parte el Dr. Ramani utilizó clasificadores para la detección automática de la enfermedad donde evaluó utilizando los métodos de minería de datos. Sus resultados muestran que se puede lograr una precisión de predicción del 76,67%. En un entorno de detección a gran escala, el EMD puede evaluarse mediante la detección de exudados (un tipo de lesiones brillantes) en imágenes de fondo de ojo. En el trabajo desarrollado por Giancardo se presenta una nueva metodología para el diagnóstico de EMD utilizando un nuevo conjunto de características basadas en el color, la descomposición de Wavelets y la segmentación automática de lesiones. Estas características se emplean para entrenar a un clasificador capaz de diagnosticar automáticamente EMD a través de la presencia de exudación. Giancardo pudo lograr un rendimiento de diagnóstico de 88% (Giancardo et al., 2012).

Gandhi en 2013 se centra en la detección automática de la RD a través de la detección de la rigurosidad de lesiones en imágenes retinianas de fondo de color. La toma de decisiones sobre el nivel de gravedad de la enfermedad fue realizada

por el clasificador SVM, el cual obtiene un 80% de exactitud en dicha detección. Esta información del algoritmo clasificador mejora la claridad en el diagnóstico de la retinopatía diabética (Gandhi & Dhanasekaran, 2013).

En este mismo año Li Thang presenta un novedoso método de clasificación de características de Splat (Garvin, Reinhardt, Abramoff, Tang, & Niemeijer, 2012) con aplicación para la detección de hemorragia retiniana en imágenes de fondo. Bajo su enfoque supervisado, las imágenes en color de la retina se dividen en segmentos no superpuestos que cubren toda la imagen. Cada segmento, es decir, splat, contiene píxeles con color y ubicación espacial similares. Se extrae un conjunto de características de cada símbolo para describir sus características en relación con su entorno, empleando respuestas de una variedad de bancos de filtros, interacciones con símbolos adyacentes e información de forma y textura. Se selecciona un subconjunto óptimo de características de splat mediante un enfoque de filtro seguido de un enfoque de envoltura. Se basa en la detección de hemorragia de retina logando a una exactitud del 87%.

En este artículo publicado en 2015, Swati Gupta, presenta una serie de experimentos sobre selección de características y clasificación de exudados usando el Teorema de Bayes. Primero se ajusta el modelo de Bayes a un conjunto de entrenamiento que consta de 15 características extraídas de cada uno de 115,867 ejemplos positivos de píxeles exudados y un número igual de ejemplos negativos (R. & P., 2015). Para encontrar el mejor SVM, se comienza con el mejor conjunto de características del clasificador Bayes, y se agrega repetidamente las características eliminadas previamente al clasificador. Se encuentra que los

clasificadores Bayes y SVM funcionan mejor que el clasificador KNN. La mejor exactitud encontrada es del 73%.

En este mismo año, Priya y Aruna presentan una investigación para diagnosticar RD, donde se utilizan dos modelos uno basado en Redes Neuronales Probabilísticas (PNN) y el segundo en SVM (R. & P., 2015), sin embargo, las imágenes utilizadas no presentan ningún tratamiento arrojando una exactitud bajo las condiciones expuestas de 89.60% correspondiente al rendimiento del segundo modelo.

Shetty et. al, en 2016 comienza procesando previamente las imágenes del fondo del ojo, las áreas dañadas de la retina consisten en lesiones oscuras y brillantes. La problemática se aborda a partir de analizar lesiones brillantes y oscuras como un todo (Sahana Shetty, Kaveri B. Kari, 2016) y partir de este planteamiento se realiza la clasificación de la RD en leve, modera y severa, dependiente del daño observado en las imágenes del fondo de ojo. De los experimentos realizados en pacientes con retinopatía diabética se obtuvo el siguiente nivel de sensibilidad, especificidad y AUC por encima del 90%.

Bhatia, 2016, este artículo se centra en la decisión sobre la presencia de enfermedades mediante la aplicación de un conjunto de algoritmos de clasificación de aprendizaje automático en las características extraídas de la salida de diferentes algoritmos de procesamiento de imágenes de la retina, como el diámetro del disco óptico, la lesión específica (microaneurismas), el nivel de imagen (Bhatia, Arora, &

Tomar, 2016). La toma de decisiones para predecir la presencia de RD se realizó utilizando una regresión logística, no obstante, el autor no reporta que exactitud obtuve en su experimento.

La contribución en 2016 de Rocha et. al, consiste en la construcción de un diccionario visual de palabras que representa puntos de interés (PoI) (Rocha et al., 2016). La novedad de su enfoque radica en localizar las lesiones DR en las imágenes del fondo óptico utilizando palabras visuales que combinan información de características contenidas dentro de las imágenes en lugar de un diccionario común para todas las clases. El diccionario de palabras visuales se aplicó para clasificar las lesiones brillantes y rojas con la validación cruzada clásica y la validación de conjuntos de datos cruzados para indicar la solidez de este enfoque. Obtuvo un área bajo la curva (AUC) del 93.3% para la detección de lesiones rojas utilizando la validación cruzada quintuple y sus propios datos que consisten en 687 imágenes de retinas normales, 245 imágenes con lesiones brillantes y 191 con lesiones rojas.

En 2017, Cabrera, et. al, propone un diagnóstico asistido por computadora basado en el procesamiento digital de imágenes retinianas para detectar la RD. El objetivo principal es clasificar automáticamente el grado de retinopatía diabética no proliferativa en cualquier imagen retiniana . Esta propuesta fue probada en una base de datos de 400 imágenes retinianas etiquetadas de acuerdo con una escala de 4 grados de retinopatía diabética no proliferativa. Como resultado, se obtuvo una sensibilidad máxima del 95% y una capacidad predictiva del 94%.

Lazar y Hajdu proponen un método para la detección automática de microaneurismas (MA) en imágenes retinianas en color. El método propuesto realiza la detección de MA a través del análisis de perfiles de sección transversal direccionales centrados en los píxeles máximos locales de la imagen pre-procesada. El método propuesto se probó en el Retinopathy Online Challenge (Lazar & Hajdu, 2017), donde demostró ser competitivo con los enfoques más modernos.

Por último, debido a la facilidad de uso de los modelos de cámara más nuevos y su costo relativamente bajo, estas cámaras pueden ser empleadas por operadores con capacitación limitada para aplicaciones de telemedicina o punto de atención (PoC). Thomas P. Karnowsk et. al, propone una técnica novedosa que utiliza imágenes de fondo de ojo de vista múltiple no calibradas para analizar la inflamación de la mácula (Giancardo et al., 2017). Esta innovación permite la detección y medición cuantitativa de áreas inflamadas por oftalmólogos remotos.

La técnica presentada se divide en tres partes: primero, una técnica de preprocesamiento mejora simultáneamente las microestructuras oscuras de la mácula e iguala la imagen; segundo, todas las vistas disponibles se registran utilizando características dispersas no morfológicas; finalmente, se calcula un flujo óptico piramidal denso para todas las imágenes y se combina estadísticamente para construir un mapa de altura de la mácula. Los resultados se presentan en tres conjuntos de imágenes sintéticas y dos conjuntos de imágenes del mundo real. Estas pruebas preliminares muestran la capacidad de inferir una inflamación mínima de 300 μm y de correlacionar la reconstrucción con la ubicación inflamada.

En la Tabla 4 se muestra un resumen de las contribuciones antes mencionadas y se presenta una clasificación respecto a la técnica utilizada, lesiones analizadas, exactitud lograda y la base de datos con la que se entrenó el algoritmo.

Tabla 4. Estado del Arte

Autor	Método	Lesión	Exactitud	Base de Datos
Zhang et. al (2005)	SVM	Microaneurismas, Venas	89.10%	45
Osare et. al (2009)	FCMs, Algoritmos genéticos, NN	No Reporta	93.50%	300
K. Sai Deepak, et al. (2012)	KNN	Edema Macular	81%	Messidor
Dr. R. Geetha Ramani, et al. (2012)	Fuzzy Means	No Reporta	76.67%	60
Luca Giancardo, et. al (2012)	Teorema de Bayes	Edema Macular	88%	Messidor
Mahendran Gandhj, et al. (2013)	SVM	Exudados	80%	NR
Li Tang, et. al (2013)	Características Splat	Hemorragias	87%	NR

Tabla 4. Estado del Arte (Continuación)

Akara Sopharak, et. Al (2014)	Teorema de Bayes y SVM	Exudados	NR	115,867 imágenes(Thammasat University)
Swati Gupta, et. al (2015)	KNN	Microaneurismas	86%	Messidor
R. Priya y P. Aruna (2015)	SVM y PNN	Exudados	89.60%	Dr. W. Ashok baskaran
Karan Bhatia, et. al (2016)	Regresión logística	Microaneurismas	NR	NR
Anderson Rocha (2016)		Hemorragias, Lesiones rojas	89.30%	Messidor
Enrique V. Carranza, et al. (2017)	SVM	Vasos sanguíneos	94%	130
Istcan Lazar y Andras Hajdu (2017)	Cross Section	Uso de la imagen completa	NR	NR
Thomas P. Karnowski, et. al (2017)		Solo dan tratamiento a las imágenes		J. Mastellone of the Hamilton Eye Institue

XI. FUNDAMENTACIÓN TEÓRICA

11.1 Procesamiento de imágenes

El procesamiento de imágenes tiene como objetivo mejorar el aspecto de las imágenes y hacer más evidentes en ellas ciertos detalles que se desean hacer notar. La imagen puede haber sido generada de muchas maneras, por ejemplo, fotográficamente, o electrónicamente, por medio de monitores de televisión. El procesamiento de las imágenes se puede en general hacer por medio de métodos ópticos, o bien por medio de métodos digitales, en una computadora.

El sistema visual humano es uno de los mecanismos de procesamiento de imágenes más poderosos que existen. Este sistema es capaz de detectar, analizar y almacenar imágenes con un gran poder de procesamiento. La visión es sin duda el sentido más usado por la especie humana, y por lo mismo frecuentemente se olvida su importancia. En general, el procesamiento de imágenes consiste en alterar la información visual para obtener mejores resultados o para aislar algunas características particulares de las imágenes (McAndrew, 2004)(Fogel et al., 2016). El impacto de esta disciplina ha sido enorme y afecta a áreas tales como la medicina, telecomunicaciones, control de procesos industriales

11.2 Espacio de Color

En el procesamiento de imágenes un espacio de color es un modelo matemático con el que se intenta describir de forma abstracta la percepción humana del color. Debido a que todos los colores pueden ser formados a partir de una combinación de colores primarios, la representación matemática se realizará

mediante tuplas de números. En esencia, un espacio de color se puede ver como un sistema coordinado donde cada color está representado por un punto.

Una imagen digital se le puede considerar como una matriz bidimensional de valores discretos y finitos de intensidad de luz. Cada punto que está representado por la intersección de una fila y columna se le denomina píxel. Una imagen a color se puede representar en algunos modelos o espacios de color de los cuales se presentan únicamente los necesarios en el desarrollo de la presente investigación. (“Procesamiento digital de imágenes,” 1996).

La Tabla muestra los espacios de color utilizados para imágenes médicas, así como una descripción de estos.

Tabla 5. Espacios de Color

Espacio de color	Descripción
Modelo RGB	Una imagen en RGB se representa por una matriz de 3 dimensiones, las dos primeras son la imagen bidimensional y la tercera pertenece a cada espacio de color, es decir una imagen RGB se puede ver como tres imágenes en escala de grises que al unir las forman colores. Los colores principales para formar cualquier color en este modelo son el Rojo, Verde y Azul.

Tabla 5. Espacios de color (Continuación)

Modelo CMY	Al igual que el modelo RGB, el CMY se forma por tres componentes, pero esta vez los colores principales cambian a Cian, Magenta y Amarillo.
Modelo HSI	En el modelo HSI, los tres componentes están formadas por tres componentes, las cuales representan la profundidad, la saturación y la intensidad de la imagen.
Modelo LUV	El espacio de color LUV es un espacio de color uniforme es también denotado como el espacio de color CIE LUV. Está basado en un diagrama de cromaticidad uniforme u-v, en donde la diferencia entre dos colores es proporcional a la distancia geométrica en el espacio de color.

El procesamiento digital de imágenes consiste en mejorar o acoplar el aspecto de una imagen digital, esto puede ser mediante su tamaño, intensidad, contraste, color, etc. (Dhanashri Dilip, 2017)

11.2 Segmentación de imágenes

11.2.1 Operaciones Morfológicas

Morfología, en el contexto de procesamiento de imágenes, significa el estudio de la topología o estructura de objetos de la imagen. El procesamiento morfológico se refiere a ciertas operaciones donde un objeto es afectado con un elemento estructural.

Existen dos operaciones morfológicas básicas, erosión y dilatación.

11.2.2 Erosión

La transformación de la erosión es el resultado de comprobar si el elemento estructurante B está completamente incluido dentro del conjunto X. (Dhanashri Dilip, 2017) Cuando no ocurre, el resultado de la erosión es el conjunto vacío:

$$\varepsilon_B(X) = X \ominus B = \{x | B_x \subseteq X\} \quad (1)$$

Cuando los objetos de la escena sean menores que el elemento estructurante, éstos desaparecerán. Otra interpretación de la erosión supone tomar el valor mínimo de la imagen en el entorno de vecindad definido por el elemento estructurante.

Su utilidad consiste en definir una geometría determinada al elemento estructurante y pasarlo sobre la imagen. Los objetos menores al elemento estructurante no aparecerán en la imagen resultante. Los objetos que queden de la transformación habrán sido degradados. Por tanto, la erosión supone una degradación de la imagen.

11.2.3 Dilatación

La dilatación es la transformación dual a la erosión. El resultado de la dilatación es el conjunto de elementos tal que al menos algún elemento del conjunto estructurante B está contenido en el conjunto X, cuando B se desplaza sobre el conjunto (Sathiya & Gayathri, 2014).

$$\delta_B(X) = X \oplus B = \{X \cap B_x \neq \emptyset\} \quad (2)$$

Esta operación representa un crecimiento progresivo del conjunto X. Al pasar el elemento estructurante dentro del conjunto, éste no se modificará. Sin embargo, en la frontera del conjunto X, al desplazar a B, el conjunto resultado se expansionará. (Dhanashri Dilip, 2017) La aplicación iterada de este operador haría degradar la imagen, haciendo coincidir el conjunto dilatado con la imagen.

La dilatación es una transformación extensiva: $X \oplus B \supseteq X$ La dilatación también se interpreta como el valor máximo del entorno de vecindad definido por el elemento estructurante.

11.2.4 Apertura

Usando los operadores elementales de erosión y dilatación se pueden diseñar operaciones de realce de las formas de los objetos. La erosión binaria suele utilizarse para eliminar pequeños objetos, práctica que suele ser utilizada en la fase de post-procesado, después de la segmentación (Sreng, Maneerat, Hamamoto, & Panjaphongse, 2018).

Este efecto puede ser subsanado con una aplicación en cascada de erosión y dilatación binaria con igual elemento estructurante. A esta operación se la llama apertura (opening):

$$\gamma_B(X) = X \circ B = \delta_B(\varepsilon_B(X)) \quad (3)$$

La apertura binaria elimina todos los objetos que no están completamente contenidos en el elemento estructurante, pero además no disminuye el tamaño a los objetos que superen la erosión. Sin embargo, la imagen resultante no recupera la misma forma de los objetos filtrados de la imagen de entrada. Esta operación puede ser ideal para la eliminación de ruido, aunque no preserva la geometría de los objetos (Dhanashri Dilip, 2017).

11.3 Máquina de Vectores de Soporte (SVM)

Recientemente, se ha prestado especial atención a las Máquinas de Vectores de Soporte (SVM) como método de clasificación. El enfoque SVM busca encontrar el hiperplano de separación óptimo entre clases enfocándose en los casos de

entrenamiento que se ubican en el borde de los descriptores de clase. Estos casos de entrenamiento se denominan vectores de soporte. Se descartan los casos de entrenamiento que no sean vectores de soporte. De esta manera, no solo se instala un hiperplano óptimo, sino que también se utilizan menos muestras de entrenamiento; por lo tanto, se logra una alta precisión de clasificación con pequeños conjuntos de entrenamiento (Mercier y Lennon 2003).

Esta característica es muy ventajosa, especialmente para los conjuntos de datos de teledetección y más específicamente para el análisis de imágenes. Se puede encontrar una formulación completa de las máquinas de vectores de soporte en varias publicaciones (Cortes y Vapnik 1995, Vapnik 1995, 1998, Theodoridis y Koutroumbas 2003).

Una máquina de vectores de soporte crea un espacio de características, que es un espacio vectorial de dimensiones finitas, cada una se representa como una "característica" de un objeto en particular. El objetivo de la SVM es entrenar un modelo que asigne nuevos objetos invisibles a una categoría particular. Lo logra creando una partición lineal del espacio de características en dos categorías. Según las características de los nuevos objetos invisibles, coloca un objeto "encima" o "debajo" del plano de separación, lo que lleva a una categorización. Esto lo convierte en un ejemplo de un clasificador lineal no probabilístico (Negri, 2018). No es probabilístico, porque las características en los nuevos objetos determinan completamente su ubicación en el espacio de características y no hay ningún elemento estocástico involucrado.

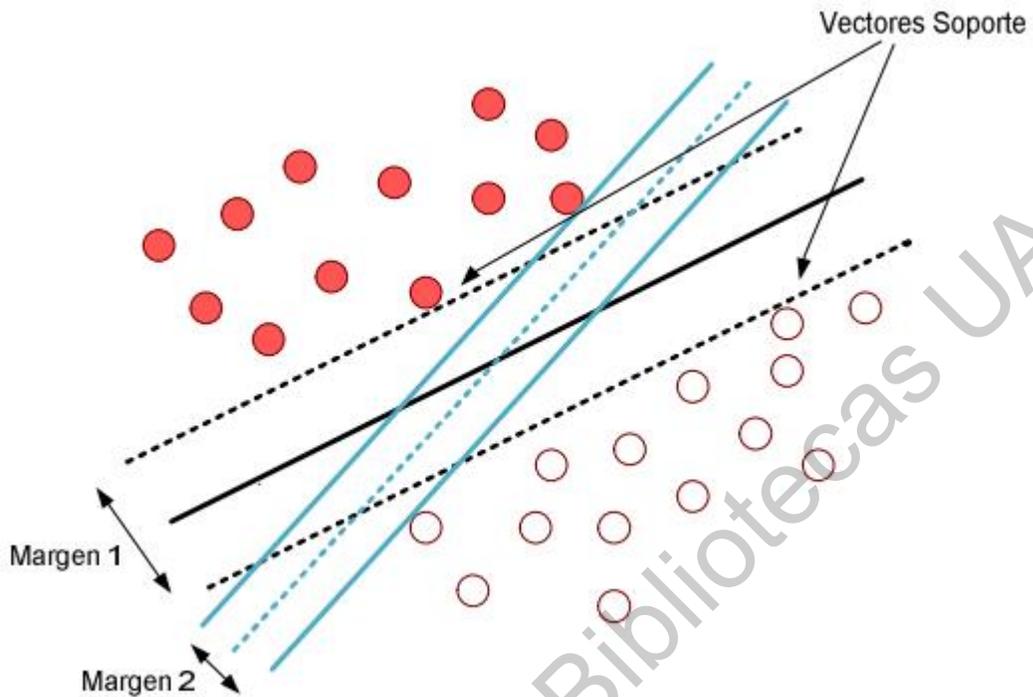


Ilustración 15. Máquina de Vectores de soporte

Los puntos de datos de entrenamiento están representados por $\{\mathbf{x}_i, y_i\}$, $i = 1, 2, \dots, N$, y $y_i \in \{-1, +1\}$, donde N es el número de muestras de entrenamiento, $y_i = +1$ y $y_i = -1$. La clasificación óptima se produce cuando dichos hiperplanos proporcionan una distancia máxima a los puntos de datos de entrenamiento más cercanos. Intuitivamente, esto tiene sentido, ya que, si los puntos están bien separados, la clasificación entre dos grupos es mucho más clara. (Chapelle, Haffner, & Vapnik, 1999)

El hiperplano de separación lineal es la entidad geométrica clave que se encuentra en el corazón de la SVM, suponiendo que existe un hiperplano que separa esos datos dado por:

$$f(\mathbf{x}) = \mathbf{x} \cdot \mathbf{w} + b \quad (4)$$

Entonces, se puede definir el margen como la suma de las distancias de los puntos más cercanos al hiperplano, es decir:

$$\gamma = \frac{1}{2} \left(\frac{\mathbf{w}}{\|\mathbf{w}\|_2} \cdot \mathbf{x}^+ - \frac{\mathbf{w}}{\|\mathbf{w}\|_2} \cdot \mathbf{x}^- \right) = \frac{1}{2\|\mathbf{w}\|_2} (\mathbf{w} \cdot \mathbf{x}^+ - \mathbf{w} \cdot \mathbf{x}^-) = \frac{2}{\|\mathbf{w}\|_2} \quad (5)$$

Donde \mathbf{x}^+ y \mathbf{x}^- representan los patrones pertenecientes a la clase positiva y negativa respectivamente.

Por tanto, el objetivo es maximizar el margen $\gamma = \frac{2}{\|\mathbf{w}\|_2}$, lo que es equivalente a minimizar la siguiente función

$$\min \frac{1}{2} \|\mathbf{w}\|^2 \quad (6)$$

sujeta a una serie de restricciones, que vienen de la condición de que las clases positivas ($y_i = 1$) deben estar separadas de las clases negativas ($y_i = -1$)

$$\mathbf{x}_i \cdot \mathbf{w} + b \geq 1 \text{ para } y_i = +1 \quad (7)$$

$$\mathbf{x}_i \cdot \mathbf{w} + b \leq -1 \text{ para } y_i = -1 \quad (8)$$

Estas restricciones (4) y (5) pueden ser unidas en una sola

$$y_i(\mathbf{x}_i \cdot \mathbf{w} + b) - 1 \geq 0 \quad \forall i \quad (9)$$

Finalmente, si juntan la ecuación (3) con la (6) se obtiene el problema primal de optimización de los SVM:

$$\begin{aligned} \min_{\mathbf{w}, b} \quad & \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s.t.} \quad & y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq 0 \quad \forall i \end{aligned} \quad (10)$$

Por lo tanto, se puede decir que este es un problema de optimización cuadrática convexa con restricciones lineales, en el que el hiperplano se obtiene minimizando la norma del vector de pesos \mathbf{w} .

Para minimizar la función (7) se usará la siguiente función:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^l \alpha_i [y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1] \quad (11)$$

donde L debe ser minimizada sobre \mathbf{w} y b , por lo tanto, se calcula $\frac{\partial L}{\partial \mathbf{w}}$ y $\frac{\partial L}{\partial b}$ e se iguala a cero, obteniendo las siguientes ecuaciones:

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i = 0 \quad (12)$$

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{b} = \sum_{i=1}^n y_i \alpha_i = 0 \quad (13)$$

que sustituidas en la ecuación (8)

$$\begin{aligned} L(\mathbf{w}, b, \alpha) &= \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \mathbf{x}_i \cdot \mathbf{x}_j - \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \mathbf{x}_i \cdot \mathbf{x}_j - \sum_{i=1}^l \alpha_i y_i b + \sum_{i=1}^l \alpha_i \\ &= \theta(\alpha) \end{aligned} \quad (14)$$

y, por tanto, el problema dual para las SVM es:

$$\begin{aligned} \max_{\alpha} \theta(\alpha) &= \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \\ \text{s.t} \quad &\alpha_i \geq 0 \quad \forall i \\ &\sum_i \alpha_i y_i = 0 \end{aligned} \quad (15)$$

Por último, se establece una condición complementaria:

$$\alpha_i^* (y_i ((\mathbf{w} \cdot \mathbf{x}_i + b^*) - 1)) = 0 \quad (16)$$

Una vez obtenida la solución óptima del problema dual (α^*, b^*) de SVM (12) de la condición complementaria y las derivadas parciales del Lagrange, se obtienen los pesos \mathbf{w}^* del problema primal mediante la ecuación dada por $\frac{\partial L}{\partial \mathbf{w}} = 0$:

$$\mathbf{w}^* = \sum_{i=1}^l y_i \alpha_i \mathbf{x}_i \quad (17)$$

mientras que el término de bias se corresponde con:

$$b^* = y_i - \mathbf{w}^* \cdot \mathbf{x}_i = y_i - \sum_{i=1}^l \alpha_i^* y_i \mathbf{x}_i \cdot \mathbf{x}_j \quad (18)$$

Para la condición (13) se tiene que si $\alpha_i^* > 0$, entonces

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b^*) = 1 \quad (19)$$

por lo tanto, estos serán los puntos que están en el hiperplano. E

En resumen, por la ecuación (14) y de la condición (16) deducimos que los puntos que definen los pesos son aquellos que están en el hiperplano óptimo, es decir, aquellos en los que $\alpha_i^* > 0$ y por tanto se tiene (16). A estos puntos se les llaman vectores soporte (Hsu & Lin, 2012).

Finalmente, el hiperplano óptimo puede representarse mediante α^* y b^* como:

$$f(\mathbf{x}, \mathbf{w}^*, b^*) = \sum_{i \in \text{Svs}} y_i \alpha_i \mathbf{x}_i \cdot \mathbf{x} + b^* \quad (20)$$

Cualquier punto de datos que satisfaga (10) que sea un Vector de soporte x_s tendrá la forma:

$$y_s(\mathbf{x}_s \cdot \mathbf{w} + b) = 1 \quad (21)$$

Sustituyendo en (9):

$$y_s \left(\sum_{m \in S} \alpha_m y_m \mathbf{x}_m \cdot \mathbf{x}_s + b \right) = 1 \quad m = 1, 2, \dots, N \quad (22)$$

Donde S denota el conjunto de índices de los vectores de soporte. S se determina al encontrar los índices i donde $\alpha_i > 0$. Multiplicar por y_s y luego usar $y_s^2 = 1$ de (4) y (5)

$$y_s^2 \left(\sum_{m \in S} \alpha_m y_m \mathbf{x}_m \cdot \mathbf{x}_s + b \right) = y_s \quad (23)$$

$$b = y_s - \sum_{m \in S} \alpha_m y_m \mathbf{x}_m \cdot \mathbf{x}_s \quad (24)$$

En lugar de utilizar un vector de soporte arbitrario x_s , es mejor tomar un promedio sobre todos los vectores de soporte en S :

$$b = \frac{1}{N_s} \sum_{s \in S} \left(y_s - \sum_{m \in S} \alpha_m y_m \mathbf{x}_m \cdot \mathbf{x}_s \right) \quad (25)$$

Ahora tenemos las variables w y b que definen la orientación óptima del hiperplano de separación y, por lo tanto, la máquina de vectores de soporte.

Dirección General de Bibliotecas UAQ

XII. METODOLOGÍA

12.1 Base de datos

Este conjunto de datos proporciona información sobre la gravedad de la enfermedad de la retinopatía diabética y el edema macular diabético para cada imagen.

IDRiD (conjunto de datos de imágenes de la retinopatía diabética india) (Porwal et al., 2018) es la primera base de datos representativa de una población india. Además, es el único conjunto de datos que constituye lesiones típicas de retinopatía diabética y también estructuras retinianas normales.

Este conjunto de datos estuvo disponible como parte de "Retinopatía diabética: desafío de segmentación y clasificación" organizado en conjunción con el Simposio internacional IEEE sobre imágenes biomédicas (ISBI-2018), Washington D.C.

El conjunto de datos se divide de la siguiente manera:

- Segmentación: consiste en Imágenes originales del fondo de color (81 imágenes divididas en tren y conjunto de prueba - Archivos JPG)
- Imágenes reales para las lesiones (microaneurismas, hemorragias, exudados duros y exudados blandos divididos en tren y conjunto de prueba - archivos TIF) y disco óptico (dividido en tren y conjunto de prueba - archivos TIF)

Clasificación de la enfermedad: consiste en Imágenes originales del fondo de color (516 imágenes divididas en juego de trenes (413 imágenes) y juego de prueba (103 imágenes) - Archivos JPG).

12.2 Experimentación

En este trabajo de investigación se propone realizar un informe asistido por computadora basado en el procesamiento digital de imágenes de retina, utilizando el software de Matlab para desarrollo de esta investigación. Nos concentramos en la detección de exudados en la mácula, ya que es un factor importante para el diagnóstico de RD proliferativa, la cual si se desarrolla puede tener consecuencias más severas, como la pérdida de la visión.

Lo primero que se realizó fue una prueba de espacios de color en las imágenes contenidas en la base de datos, esto para reafirmar que el espacio de color característico que aporta más información para nuestro objeto de estudio es el RGB, el cual permite realizar un adecuado tratamiento a las imágenes y así mismo aportar en la segmentación de estas.

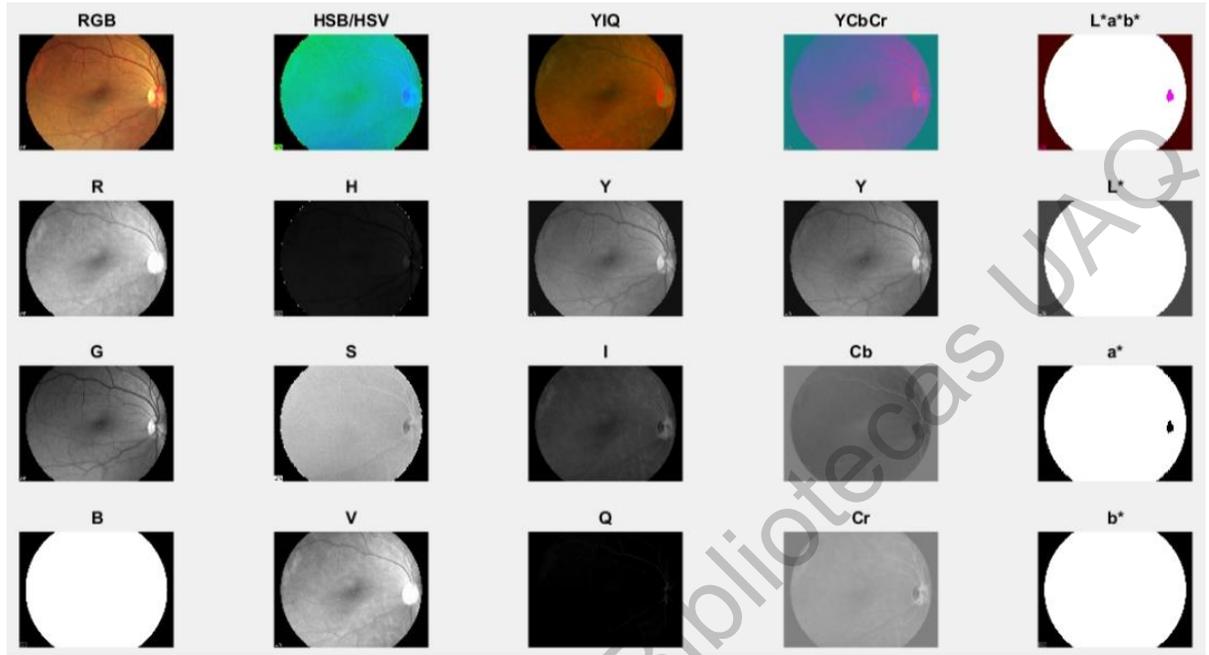


Fig. 4. Prueba de Espacios de Color en Imágenes de Retina

En una etapa inicial, se realiza el procesamiento de la imagen, en la cual se aíslan exudados duros, para extraer características que pueden ser utilizadas por SVM para determinar su presencia. Posteriormente, se realiza el aislamiento de vasos sanguíneos, los cuales pueden contribuir a la detección de otras anomalías que se pueden utilizar para realizar el informe.

En la Figura 5, se describe de manera general los pasos mínimos necesarios para realizar la clasificación de patrones a partir de las imágenes implementando el clasificador basado en SVM.

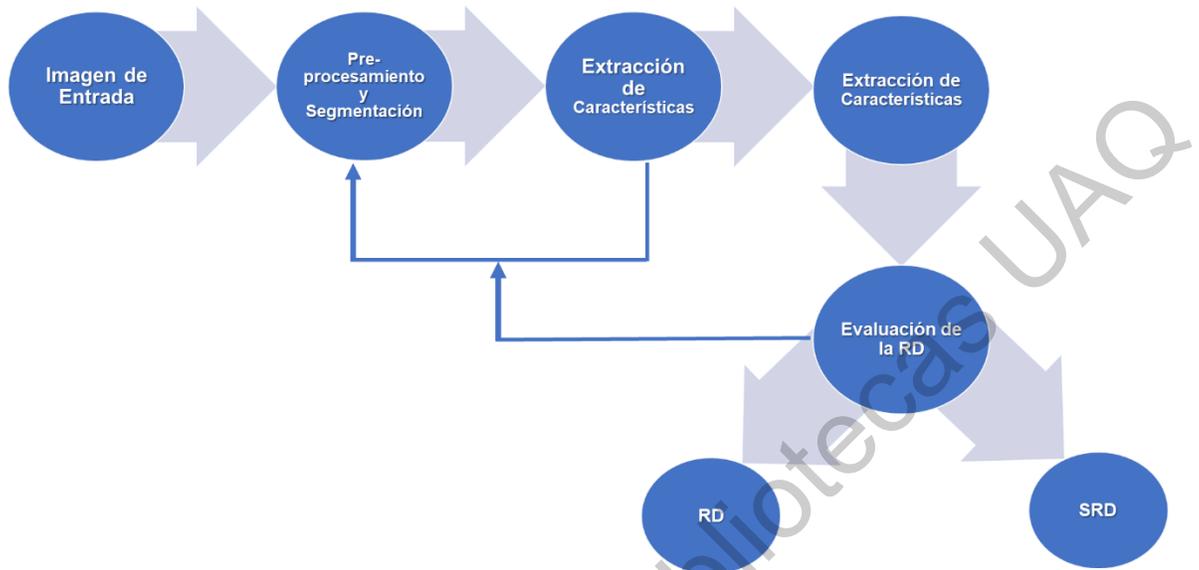


Fig. 5. Metodología: Se tiene una imagen de entrada a la que se le aplica la segmentación y procesamiento, se aplica el clasificador SVM y el resultado es RD o SRD.

La iluminación desigual dentro de las imágenes retinianas generalmente es causada por el proceso de adquisición de imágenes y el foco principal del análisis de imágenes retinianas (vista nervio óptico y vista macular). En nuestro conjunto de datos, la mayoría de las imágenes fueron capturadas con el propósito de una vista macular en la cual la iluminación está altamente enfocada en el área macular y los píxeles de la imagen en el anillo exterior de saturación de píxeles.

Por lo tanto, el preprocesamiento de la imagen se realiza primero para estandarizar el tamaño de la imagen y mejorar la calidad de la imagen retiniana. Los siguientes procedimientos se utilizan para pre-procesar las imágenes de la retina según las métricas de evaluación de calidad de imagen.

1. Cambiar el tamaño de la imagen a 576×720 píxeles para estandarizar el tamaño de la imagen y reducir el tiempo de cálculo.
2. Conversión de imagen en color RGB al canal verde, seguido de la eliminación de pequeños ruidos utilizando un filtro mediano.
3. Corrección gamma para mejorar los valores de intensidad para la binarización de imágenes.

La segmentación de imágenes puede considerarse como el principal paso de procesamiento en muchas aplicaciones de procesamiento de imágenes. Se han presentado numerosas aplicaciones en los métodos de segmentación basados en la intensidad de la imagen, el color, los bordes y la textura.

12.2.1 Exudados

En la Fig. 6 se muestra la detección de exudados duros. Para obtener los exudados, que es la zona de interés deseada, se descompone la imagen original Fig. 6(a) en los canales RGB para así tomar únicamente la componente en verde Fig. 6(b), esto debido a que este canal es el que nos ofrece una mayor información de la imagen para segmentar los exudados. El canal verde se binariza (método Otsu) ("Umbral de histograma global mediante el método de Otsu - MATLAB otsuthresh - MathWorks América Latina," n.d.) Fig. 6(c) y posteriormente se aplica una 'Máscara del disco óptico' Fig. 6(d) (Esta máscara es explicada en el inciso B), ya que el disco óptico posee un color similar al de los exudados, como se puede ver en la Fig. 6(a), por lo que al aplicar esta máscara se borra de la imagen dicho disco.

Prosiguiendo con la segmentación se utilizan operaciones morfológicas Fig. 6(e) (dilatación, erosión, abrir, sección) que ayuden a la reducción del ruido en la imagen.

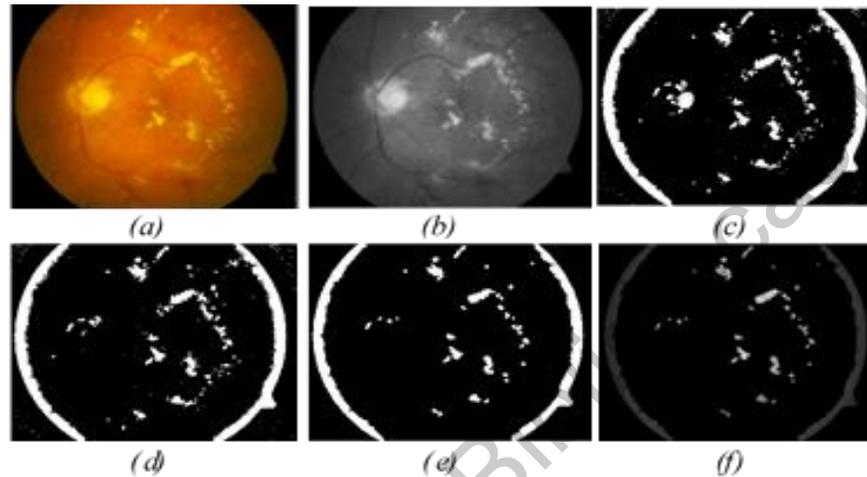


Fig. 6 Exudados Duros

12.2.2 Máscara de Disco óptico

En la Fig. 7 se describen los pasos para realizar la máscara del disco o nervio óptico. Para realizar esta máscara, la imagen original Fig. 7(a) se descompone en los canales RGB y solo se aísla el canal verde Fig. 7(b) que es el canal que resalta de mejor manera la parte del disco óptico. La imagen original RGB se cambia a la paleta CMY y de esta se toma solo el canal cian Fig. 7(c) que oscurece la parte del disco óptico. Se realiza una diferencia de los canales verde y cian Fig. 7(d), por lo que obtenemos una imagen casi en dos tonalidades donde se puede percibir que resalta la característica buscada. Se binariza la imagen obtenida de la diferencia Fig. 7(e) y por último se realiza el complemento Fig. 7(f) de la binarización,

resultando una máscara del tamaño del disco óptico, que nos permitirá cubrirlo por completo para que en la segmentación de exudados duros no se confunda

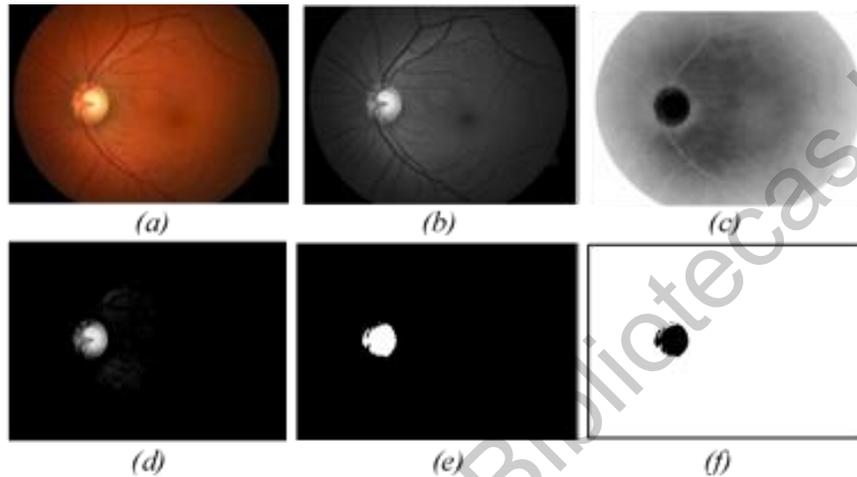


Fig. 7 Máscara de Disco Óptico

12.2.3 Vasos Sanguíneos

La Fig. 4, muestra el proceso que se lleva para resaltar los vasos sanguíneos del ojo en un fondo negro. La imagen Fig. 7(a) es la imagen original tomada directamente de la base de datos, esta imagen se pasa de RGB a los componentes CMY para aislar únicamente la componente cian Fig. 7(b). Se aplican operaciones morfológicas para el tratamiento de la imagen (erosión, abrir, dilatación) Fig. 7(c), a continuación, se realiza una diferencia entre las imágenes Fig. 7(b) y Fig. 7(c). El resultado es una imagen un tanto obscura Fig. 7(d) en la que con dificultad se pueden notar las venas oculares a simple viste, por lo que se binariza con el objetivo

de resaltarlas en blanco Fig. 7(e). Y por último para reducir el ruido en la imagen se aplica un filtro gaussiano Fig. 7(f).

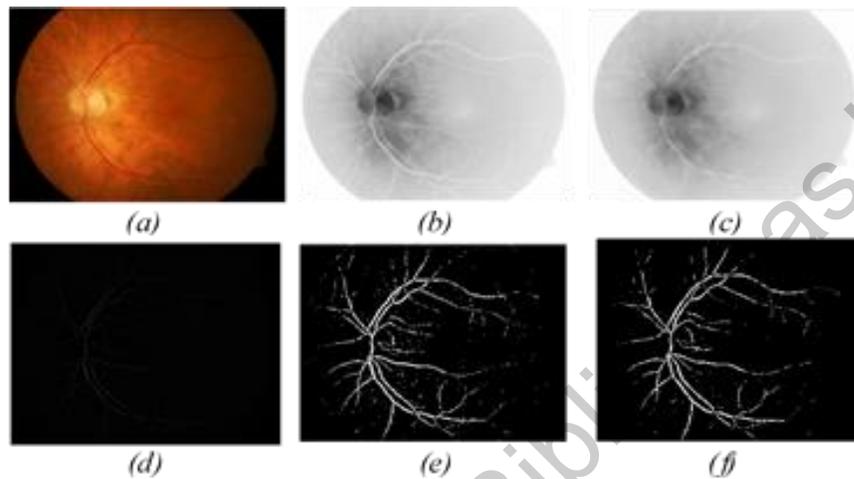


Fig. 8 Vasos Sanguíneos

Es así como mediante el procesamiento y segmentación de las imágenes podemos resaltar las características que se ocupan para el estudio en curso.

La extracción de características incluye evaluar las diversas características de una imagen segmentada para formar un vector de características requerido para ingresar el clasificador SVM. La extracción de características es un proceso en el que se extraen varias características de la imagen segmentada. Para capturar la dependencia espacial de los valores de nivel de gris, se utiliza ampliamente una matriz de dependencia bidimensional conocida como matriz de coincidencia de nivel de gris.

Las siguientes son las características que se extraen de las imágenes segmentadas:

1. ENERGÍA: La energía corresponde al valor medio al cuadrado de la imagen típicamente medida con respecto al valor medio global. La energía de una imagen devuelve la suma de elementos al cuadrado en el GLCM.

$$- \sum_i \sum_j G(i,j) \log G(G(i,j)) \quad (26)$$

2. CONTRASTE: la función de contraste mejora el contraste de una imagen. El contraste de una imagen devuelve una medida del contraste de intensidad entre un píxel y su vecino sobre toda la imagen.

$$\sum_i \sum_j (i,j)^2 G(i,j) \quad (27)$$

3. HOMOGENEIDAD: la homogeneidad refleja la uniformidad de varios píxeles en una imagen y expresa cuán similares son todos. La homogeneidad de la imagen devuelve un valor que mide la cercanía de la distribución de elementos en el GLCM.

$$- \sum_i \sum_j (G(i,j))^2 / [1 + |i - j|] \quad (28)$$

4. ENTROPÍA: la entropía es una característica que mide la aleatoriedad de la distribución de nivel de gris.

$$-\sum_i \sum_j G(i,j) \log G(i,j) \quad (29)$$

5. CORRELACIÓN: La operación llamada correlación está estrechamente relacionada con la convolución. En correlación, el valor de un píxel de salida también se calcula como una suma ponderada de píxeles vecinos. La diferencia es que la matriz de pesos, en este caso llamada núcleo de correlación, no se rota durante el cálculo. Por lo tanto, la operación de correlación devuelve una medida de la correlación de un píxel con su vecino en toda la imagen.

XIII. RESULTADOS

Los resultados obtenidos en este estudio bajo las condiciones antes explicadas se muestran a continuación.

De las 130 imágenes con que cuenta la base de datos, 73 de ellas están etiquetadas como 'ojos sanos' o sin exudados y los 57 restantes son 'lesiones presentes' o exudados evidentes. En la Tabla V, se muestra un resumen de los resultados para cada método aplicado, un SVM de función lineal y un SVM aplicando con un kernel gaussiano. El mejor desempeño fue adquirido usando una clasificación binaria de SVM con función de núcleo lineal.

La evaluación del rendimiento del clasificador se realiza mediante el cálculo de parámetros tales como Verdadero positivo (TP), Verdadero negativo (TN), Falso positivo (FP) y Falso negativo (FN). TP es el número de imágenes anormales clasificadas como anormales por el sistema de detección. TN es el número de imágenes que son realmente normales y clasificadas como normales por el procedimiento de detección. FP es el número de imágenes normales que se predice que son anormales y FN es el número de imágenes anormales, clasificadas por el procedimiento que se utilizará. Se calculan la sensibilidad, la especificidad y la precisión.

La sensibilidad es la medida del porcentaje de imágenes anormales clasificadas por el procedimiento de detección.

$$\text{Sensibilidad} = \text{TP} / (\text{TP} + \text{FN}) \times 100 \quad (30)$$

La especificidad se define como el porcentaje de imágenes normales clasificadas por el sistema.

$$\text{Especificidad} = \text{TN} / (\text{TN} + \text{FP}) \times 100 \quad (31)$$

La precisión es el porcentaje de imágenes normales y anormales clasificadas correctamente.

$$\text{Precisión} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FN} + \text{FP}) \times 100 \quad (32)$$

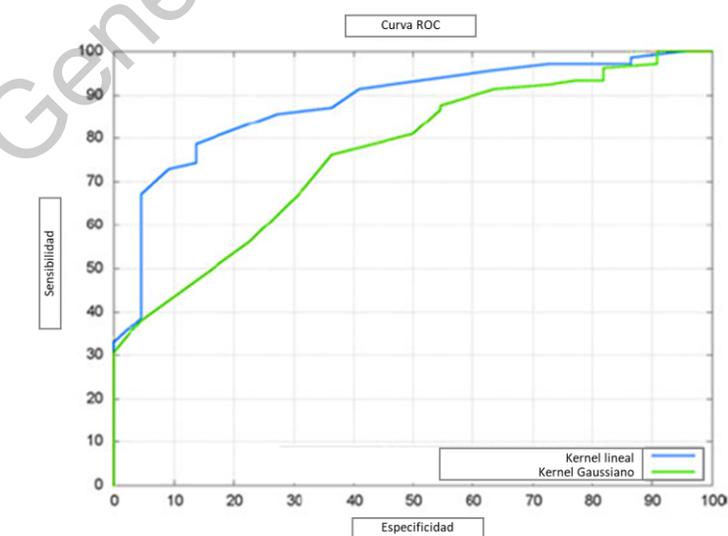


Fig. 9 Curva ROC

La Tabla 6, muestra los resultados para la clasificación en dos categorías como son con exudados presentes y sin exudados, después del entrenamiento y pruebas con imágenes de cada categoría.

Tabla 6. Resultados

	SVM	SVM (kernel gaussiano)
Exactitud	92.4%	80.8%
Sensibilidad	87.3%	82.1%
Especificidad	84.6%	66.2%

XIV. CONCLUSIÓN

La etapa de preprocesamiento de las imágenes de retina es una parte crucial para la detección de los exudados duros. De este preprocesamiento depende la cantidad de regiones candidatas a ser exudados duros que son segmentadas la conservación de sus características de forma y color.

Es importante definir un tamaño estándar para las imágenes de retina debido a que, de este modo, conservamos los valores de parámetros de los algoritmos, para diferentes bases de datos.

De acuerdo con los experimentos, el mejor modelo de clasificación para la detección de retinopatía diabética resulto ser la clasificación de SVM a partir de un kernel lineal. Este modelo de clasificación es capaz de igualar y supera los resultados de los otros algoritmos si se encuentran los parámetros correctos.

Se han presentado algoritmos eficientes para el aislamiento de exudados duros y vasos sanguíneos a partir de procesamiento y segmentación de imágenes. Las características propuestas muestran un gran potencial para la detección y clasificación de RD. SVM puede detectar la RD con una sensibilidad de casi el 90%, mientras que se puede clasificar con una exactitud del 92%. SVM constantemente muestra mejores resultados que otros algoritmos de aprendizaje automático.

Podemos concluir que el procesamiento de imágenes retina tiene el potencial de desempeñar un papel importante en el diagnóstico de la retinopatía diabética. Los resultados son alentadores y una futura evaluación clínica integrará los algoritmos presentados en una herramienta realizar informes de la retinopatía. Otros trabajos futuros son la detección de micro-aneurismas y hemorragias, además de los exudados duros y los vasos sanguíneos, para mejorar la precisión y la sensibilidad de nuestro detector de retinopatía.

Los resultados obtenidos en esta tesis superan a los del estado del arte. Sin embargo, debido a la diversidad de bases de datos con la que fueron realizados los experimentos del estado del arte, los resultados no pueden ser comparables.

Dirección General de Bibliotecas UAQ

XV. REFERENCIAS

- Bhatia, K., Arora, S., & Tomar, R. (2017). Diagnosis of diabetic retinopathy using machine learning classification algorithm. *Proceedings on 2016 2nd International Conference on Next Generation Computing Technologies, NGCT 2016*, 3(2), 347–351. <https://doi.org/10.1109/NGCT.2016.7877439>
- Chapelle, O., Haffner, P., & Vapnik, V. N. (1999). Support vector machines for histogram-based image classification. *IEEE Transactions on Neural Networks*, 10(5), 1055–1064. <https://doi.org/10.1109/7X2.788646>
- Dabeer, S., Khan, M. M., & Islam, S. (2019). Cancer diagnosis in histopathological image: CNN based approach. *Informatics in Medicine Unlocked*, 16(August), 100231. <https://doi.org/10.1016/j.imu.2019.100231>
- De Postura, D., Salinas, C. A. A., Hernández Jiménez, S., Hernández, M., Juan, Á., & Ávila, E. H. (n.d.). ACCIONES PARA ENFRENTAR A LA DIABETES. Retrieved from <https://www.anmm.org.mx/publicaciones/CAnivANM150/L15-Acciones-para-enfrentar-a-la-diabetes.pdf>
- Deepak, K. S., & Sivaswamy, J. (2012). Automatic assessment of macular edema from color retinal images. *IEEE Transactions on Medical Imaging*, 31(3), 766–776. <https://doi.org/10.1109/TMI.2011.2178856>
- Dhanashri Dilip, B. (2017). A Brief Review of Image Segmentation Based on Thresholding Technique. *International Journal for Research in Applied Science and Engineering Technology*, V(III), 293–296. <https://doi.org/10.22214/ijraset.2017.3055>
- Dong, J., Du, H. S., Wang, S., Chen, K., & Deng, X. (2004). A framework of Web-based decision support systems for portfolio selection with OLAP and PVM. *Decision Support Systems*, 37(3), 367–376. [https://doi.org/10.1016/S0167-9236\(03\)00034-4](https://doi.org/10.1016/S0167-9236(03)00034-4)
- Espinoza Diaz, C., Morocho Zambrano, A., Valencia Naranjo, A., Shiguango Shiguango, N., Morales Carrasco, A., Córdova Córdova, H., ... Albuja Diaz, L. (2018). Diabetes mellitus tipo 2 y su asociación con factores de riesgo cardiovascular en pacientes hipertensos. *Diabetes Internacional*, 10(1).
- Estadísticas en México - Federación Mexicana de Diabetes. (n.d.). Retrieved March 30, 2019, from <http://fmd diabetes.org/estadisticas-en-mexico/>
- Fogel, D. B., Liu, D., & Keller, J. M. (2016). Fundamentals of Computational Intelligence. *Fundamentals of Computational Intelligence*. <https://doi.org/10.1002/9781119214403>
- Gandhi, M., & Dhanasekaran, R. (2013). Diagnosis of diabetic retinopathy using

morphological process and SVM classifier. *International Conference on Communication and Signal Processing, ICCSP 2013 - Proceedings*, 873–877. <https://doi.org/10.1109/iccsp.2013.6577181>

- Garvin, M. K., Reinhardt, J. M., Abramoff, M. D., Tang, L., & Niemeijer, M. (2012). Splat Feature Classification With Application to Retinal Hemorrhage Detection in Fundus Images. *IEEE Transactions on Medical Imaging*, 32(2), 364–375. <https://doi.org/10.1109/tmi.2012.2227119>
- Gascueña, J. M., Fernández-caballero, A., & González, P. (n.d.). *Ontologies for Student and Domain Models in Adaptive and Collaborative Learning System*.
- Giancardo, L., Meriaudeau, F., Karnowski, T. P., Li, Y., Garg, S., Tobin, K. W., & Chaum, E. (2012). Exudate-based diabetic macular edema detection in fundus images using publicly available datasets. *Medical Image Analysis*, 16(1), 216–226. <https://doi.org/10.1016/j.media.2011.07.004>
- goleman, daniel; boyatzis, Richard; Mckee, A. (2019). Hands-on Machine Learning. In *Journal of Chemical Information and Modeling* (Vol. 53). <https://doi.org/10.1017/CBO9781107415324.004>
- Hsu, C. W., & Lin, C. J. (2002). A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 13(2), 415–425. <https://doi.org/10.1109/72.991427>
- Kalisiak, M., & De Van Panne, M. (2001). A grasp-based motion planning algorithm for character animation. *Journal of Visualization and Computer Animation*, 12(3), 117–129. <https://doi.org/10.1002/vis.250>
- Karnowski, T. P., Ruggeri, A., Tobin, K. W., Chaum, E., Favaro, P., Grisan, E., ... Meriaudeau, F. (2010). Textureless Macula Swelling Detection With Multiple Retinal Fundus Images. *IEEE Transactions on Biomedical Engineering*, 58(3), 795–799. <https://doi.org/10.1109/tbme.2010.2095852>
- Kumar, H. S. V., Pt, B., & Madhuri, R. (2016). *A Novel Method for Image Analysis and Exudates Detection in Retinal Images*. 4(1), 219–223.
- Lazar, I., & Hajdu, A. (2013). Retinal microaneurysm detection through local rotating cross-section profile analysis. *IEEE Transactions on Medical Imaging*, 32(2), 400–407. <https://doi.org/10.1109/TMI.2012.2228665>
- McAndrew, A. (2004). *An Introduction to Digital Image Processing with Matlab Notes for SCM2511 Image Processing 1 Semester 1*.
- Mistry, P., Vikhe, P., & Kadu, C. (2015). Diabetic Retinopathy Stages Detection Using Fundus Images. *International Journal of Engineering Research and General Science*, 3(2), 50–58.
- Negri, P. (2018). A MATLAB SMO implementation to train a SVM classifier: Application to multi-style license plate numbers recognition. *Image Processing*

On Line, 8, 37–50. <https://doi.org/10.5201/ipol.2018.173>

- Pedrycz, W., Sillitti, A., & Succi, G. (2016). Computational intelligence: An introduction. *Studies in Computational Intelligence*, Vol. 617, pp. 13–31. https://doi.org/10.1007/978-3-319-25964-2_2
- Porwal, P., Pachade, S., Kamble, R., Kokare, M., Deshmukh, G., Sahasrabudhe, V., & Meriaudeau, F. (2018). *Indian Diabetic Retinopathy Image Dataset (IDRID): A Database for Diabetic Retinopathy Screening Research*. <https://doi.org/10.21227/H25W98>
- Procesamiento digital de imágenes. (1996). *Perfiles Educativos*, (72).
- R., P., & P., A. (2015). Diagnosis of Diabetic Retinopathy Using Machine Learning Techniques. *ICTACT Journal on Soft Computing*, 03(04), 563–575. <https://doi.org/10.21917/ijsc.2013.0083>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... Ng, A. Y. (2017). *CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning*. 3–9. Retrieved from <http://arxiv.org/abs/1711.05225>
- Rocha, A., Carvalho, T., Jelinek, H. F., Goldenstein, S., & Wainer, J. (2012). Points of interest and visual dictionaries for automatic retinal lesion detection. *IEEE Transactions on Biomedical Engineering*, 59(8), 2244–2253. <https://doi.org/10.1109/TBME.2012.2201717>
- Rojas-Martínez, R., Basto-Abreu, A., Aguilar-Salinas, C. A., Zárate-Rojas, E., Villalpando, S., & Barrientos-Gutiérrez, T. (2018). Prevalence of previously diagnosed diabetes mellitus in Mexico. *Salud Publica de Mexico*, 60(3), 224–232. <https://doi.org/10.21149/8566>
- Sahana Shetty, Kaveri B. Kari, J. A. R. (2016). Detection of Diabetic Retinopathy Using Support Vector Machine _SVM_. *International Journal of Emerging Technology in Computer Science & Electronics*, 23(6), 976–1353.
- Sathiya, G., & Gayathri, P. (2014). Automated detection of diabetic retinopathy using GLCM. *International Journal of Applied Engineering Research*, 9(22), 7019–7027. <https://doi.org/10.1109/INTERCON.2017.8079692>
- Sreng, S., Maneerat, N., Hamamoto, K., & Panjaphongse, R. (2018). Automated diabetic retinopathy screening system using hybrid simulated annealing and ensemble bagging classifier. *Applied Sciences (Switzerland)*, 8(7). <https://doi.org/10.3390/app8071198>
- Student, S. M., Landran, C., & Kaur, G. (2015). Review on: Detection of Diabetic Retinopathy using SVM and MDA. *International Journal of Computer Applications*, 117(19), 975–8887.
- Umbral de histograma global mediante el método de Otsu - MATLAB otsuthresh - MathWorks América Latina. (n.d.). Retrieved March 30, 2019, from

<https://la.mathworks.com/help/images/ref/otsuthresh.html>

Zachariah, S., Wykes, W., & Yorston, D. (2015). Grading diabetic retinopathy (DR) using the Scottish grading protocol. *Community Eye Health Journal*, 28(92), 72–73.

Zhang, X., & Chutatape, O. (2005). A SVM approach for detection of hemorrhages in background diabetic retinopathy. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN.2005.1556284>

Dirección General de Bibliotecas UNQ

XVI. ANEXOS

16.1 Carta de Aceptación de artículo a Congreso Internacional



IEEE COLOMBIAN CONFERENCE ON APPLICATIONS IN COMPUTATIONAL INTELLIGENCE



IEEE
Computational
Intelligence
Society



IEEE COLOMBIA

Bogotá D.C., Mayo 30 de 2019

Ingeniera
Maria Fernanda Cisneros Guzman
Facultad de Ingeniería
Universidad Autónoma de Querétaro

Para la *IEEE Colombian Conference on Applications of Computational Intelligence (IEEE CoICACI 2019)* es un placer anunciar que el trabajo titulado "*Classification of diabetic retinopathy based hard exudates patterns, using images processing and SVM*" con ID 55 y autores: *Maria Fernanda Cisneros Guzman, Saul Tovar-Arriaga, Jesus Carlos Pedraza Ortega and Arturo Gonzalez Gutierrez* ha sido **ACEPTADO** para presentación **ORAL** en la conferencia.

Todos los trabajos enviados al IEEE CoICACI 2019 tuvieron que pasar un proceso riguroso que incluyó por lo menos dos revisores especializados en el área. Solicitamos amablemente que tenga en cuenta las revisiones realizadas y ajuste su artículo para mejorar la calidad y someterlo nuevamente para el *camera-ready*.

La versión final deberá enviarse como máximo para el 22 de mayo de 2019. De esta forma podrá ser incluida en la versión electrónica de los *proceedings* y posteriormente en la librería digital de IEEE Xplore. Recuerde que, si el artículo está en español, por lo menos el título, resumen y palabras clave deben estar en inglés, de otra forma el artículo no será publicado. También, al menos uno de los autores deberá estar registrado bajo la categoría R1 o R2 y el trabajo deberá ser presentado durante la conferencia.

Si necesita cuenta de cobro o factura, por favor comuníquese al correo colombia@ieee.org.co con información de la institución (dirección, número telefónico, NIT, etc).

Fecha importantes:
Camera-ready Submission: Mayo 22 de 2019.
Registro deadline: Mayo 22 de 2019
Conferencia: Junio 5 al 7 de 2019

Recuerde: solo artículos presentados en la conferencia son elegibles para publicar en el IEEE Xplore.

En caso de tener más dudas, por favor contactese a cis@ieee.org.co

Agradeciendo la atención prestada y esperando contar con su participación en el evento.

Cordialmente,



Alvaro David Orjuela Cañón
General Co-Chair
IEEE Colombian Conference on Applications in Computational Intelligence – IEEE CoICACI 2019

IEEE Sección Colombia: Calle 67 no. 6 - 80 Oficina 904, Edificio Torre Ejecutiva. Tel: + 57 1 2122088
Correos Electrónica: colombia@ieee.org.co

COICACI 2019

2nd IEEE COLOMBIAN CONFERENCE ON APPLICATIONS IN COMPUTATIONAL INTELLIGENCE

Certificate

On behalf of the IEEE Colombian Conference on Applications in Computational Intelligence – IEEE ColCACI 2019, the organizing committee certifies that

María Fernanda Cisneros Guzmán

participated as speaker of the paper entitled:

Classification of diabetic retinopathy based hard exudates patterns, using images processing and SVM

during the conference.

June 5th - 7th, 2019 in Barranquilla – Colombia


David Orjuela Cañón
General Chair


Oscar Javier Rodríguez
IEEE Colombia Section Chair



Classification of diabetic retinopathy based on hard exudates patterns, using images processing and SVM.

Fernanda Cisneros-Guzmán, Saúl Tovar-Arriaga, IEEE Senior Member, Carlos Pedraza, IEEE Senior Member, Arturo González-Gutierrez
 Facultad de Ingeniería
 Universidad Autónoma de Querétaro
 Querétaro, México.
 mfcg_14@hotmail.com

Abstract— Diabetic retinopathy (DR) is an ocular disease very common on diabetic patients. It is developed when the patient present a high level of glucose in blood which in consequence results in damage on the retina bloods vessels. The diagnostic of DR consists on the detection of different characteristics presented on the back of the eyeball, like microaneurysms, exudates, retina hemorrhages and thickness of veins. On this article we propose the detection of hard exudates and the segmentation of blood vessels through image processing for retinopathy detection. The main goal is the automatic classification images that present exudates or not. On an early step, the isolated characteristics by means of the image segmentation can be used for a support vector machine to determine the exudates presence. This proposal has been tested on a database of 130 images and the results obtained a maximum sensitivity of the 87.3% and a specificity 84.6%. Although the proposal is focuses on detected diabetic retinopathy it has been found that it could be used for the progression and diagnosis of macular edema.

Keywords— retinopatía diabética, máquina de vectores de soporte, diagnostico automatizado, procesamiento de imágenes.

I. INTRODUCCIÓN

La Academia Nacional de Medicina de México ha declarado que en México la Diabetes Mellitus (DM) es la segunda causa de muerte en hombres y la primera en mujeres, esta enfermedad causó cerca de 83,000 muertes en el país, de acuerdo con cifras recolectadas desde el año 2015[1]. La Retinopatía Diabética (RD) es una complicación visual, crónica y específica de la diabetes, tiene una prevalencia del 43.6% a nivel internacional, y en México se estima una prevalencia del 31.5% de acuerdo con la Federación Mexicana de Diabetes A.C.[2]. La RD sigue siendo la causa principal de pérdida de visión en poblaciones de adultos en edad laboral, se desarrolla con el tiempo y se asocia a la deficiencia en el control de lípidos sanguíneos, presión arterial y glucosa en sangre. La RD de acuerdo con la clasificación escocesa se divide de acuerdo con el tipo de afección que tenga el paciente, como se muestra en la tabla I[3]. Los exudados duros son lesiones en forma de depósitos blancos o amarillentos, que cuando se presentan en la mácula son un signo de edema macular actual o anterior. El edema macular más frecuente es el asociado a la RD[4]. Se le llama edema macular al acúmulo de líquido y la inflamación en la mácula, la parte del ojo encargada de la visión fina de los detalles y la visión central, y se desarrolla cuando los vasos sanguíneos de la retina tienen fugas de fluidos.

TABLA I. CLASIFICACIÓN ESCOCESA DE RETINOPATÍA DIABÉTICA[3]

Grado de retinopatía diabética	Hallazgos oftalmológicos observables
RD Ausente	•No hay anomalías
RD No proliferativa leve	•Microaneurismas
RD No proliferativa moderada	•Microaneurismas •Hemorragias
RD No proliferativa severa	•Hemorragias intrarretinianas •Cuentas venosas definidas •Anomalías microvasculares intrarretinianas. •Exudados
RD Proliferativa	RD no proliferativa severa y 1 o más de los siguientes: •Neovascularización •Hemorragia vítrea/preretiniana

Se han realizado varios esfuerzos en la detección automática de RD. Sin embargo, en este artículo se presentan ejemplos significativos más recientes basados en Aprendizaje Automático (ML), sin tomar en cuenta las contribuciones realizadas con Aprendizaje Profundo (DL). A pesar de que los avances en DL han sido muy importantes, este tipo de aprendizaje requiere de bases de datos muy amplias que deben estar etiquetadas de manera adecuada. Las bases de datos públicas disponibles[5][6] presentan varios problemas para el uso de DL: la mayoría de las imágenes no presentan RD (o solo presentan de un tipo de RD), algunas imágenes están mal etiquetadas, hay presentes otro tipo de enfermedades, etc. Esto afecta en el entrenamiento de la red neuronal, y puede llevar a sobre-entrenamiento.

En este trabajo de investigación se emplean técnicas de Aprendizaje Automático en las cuales no es necesario contar un gran número de imágenes y que al mismo tiempo pueden ofrecer un excelente grado de reconocimiento[7][8]. Así mismo, las bases de datos disponibles son suficientes para realizar un buen entrenamiento. Una comparación entre ML y DL se puede observar en la tabla II.

TABLA II. CARACTERÍSTICAS DEL APRENDIZAJE AUTOMÁTICO Y EL APRENDIZAJE PROFUNDO[9]

Aprendizaje automático	Aprendizaje profundo
Buenos resultados con pocos datos +	Requieren grandes cantidades de datos -
Rápido entrenamiento +	Carga computacional intensa -
Se necesitan diferentes características y clasificadores para alcanzar buenos resultados -	Las características y clasificadores aprenden automáticamente +
La exactitud no mejora después de un punto -	La exactitud no tiene un límite de mejora +

En [10] se aplicó clasificadores para la detección automática de la enfermedad, utilizando métodos de extracción de datos donde por medio del procesamiento de imágenes se resaltan los micro-aneurismas en la imagen como característica principal, ocupando el método de validación cruzada y obteniendo una exactitud del 76.67% en la predicción de la enfermedad. Mahendran[11] consigue una exactitud de 88.10% en la detección automática de RD mediante la segmentación de exudados en las imágenes de retina del fondo de color y también clasifica el rigor de las lesiones. La toma de decisiones del nivel de gravedad de la enfermedad fue realizada por el clasificador SVM.

TABLA III. ESTADO DEL ARTE

Autor	Lesión	Validación	Exactitud
Ramani, et al. (2012)[10]	Microaneurismas	Validación cruzada	76.67%
Gandhi et al. (2013)[11]	Exudados	No reporta	88.10%
Swati Gupta, et al. (2015)[12]	Microaneurismas	70% entrenamiento y 30% de validación	85.60%
Sahana Shetty, et al. (2016)[13]	Microaneurismas	No reporta	96.90%
Enrique V. Carrera, et al. (2017)[14]	Microaneurismas, Exudados, Vasos sanguíneos	No reporta	94%
Ramya (2018)[15]	Exudados y Hemorragias	70-30	86%

Swati en 2015[12] mostró una exactitud del 85.60% en la clasificación del grado de RD. Para detectar microaneurismas retinales y exudados, las imágenes de los fondos retinianos se toman del conjunto de datos de Messidor. Después del preprocesamiento, se realizan operaciones morfológicas para encontrar la característica y luego se extraen las características, como GLCM y Splat para la clasificación.

Sahana en 2016, obtiene como resultado una exactitud del 94% en la predicción de RD[13]. Comienza su estudio con el procesamiento previo de las imágenes del fondo de ojo, eliminando el disco óptico del fondo del ojo y luego separando el tejido vascular del área dañada de la retina. Las áreas dañadas de la retina consisten en lesiones oscuras y brillantes. Morfología matemática se utiliza para detectar la presencia de lesiones oscuras.

En 2017, en una etapa inicial de procesamiento de imágenes Carrera aísla vasos sanguíneos, micro aneurismas y exudados duros para extraer características que pueden ser utilizadas por SVMs para determinar el grado de retinopatía de cada imagen[14]. Esta propuesta se ha probado en una base de datos de 400 imágenes retinales etiquetadas según una escala de retinopatía diabética no proliferativa de 4 clases. Como resultado, se obtuvo una sensibilidad máxima del 95% y una capacidad predictiva del 94%.

En 2018, Ramya propone una técnica para el descubrimiento del nivel de afección de la RD, se acentúa en la presencia de dos tipos de RD, hemorragias y exudados[15].

Estos tipos pueden eliminarse utilizando imágenes de fondo de ojo de pacientes y manejando estas imágenes de fondo a través de un método de preparación de imagen adecuado. A la luz de la proximidad de este tipo y su suma en las imágenes de fondo, se decide el nivel de RD en los sujetos de estudio, reportando como resultado una exactitud de 85%.

Máquina de Vectores de Soporte (SVM) es un algoritmo de aprendizaje supervisado perteneciente a Aprendizaje Automático, que es denominado como método de kernel o máquina de kernel.

Para clasificación o regresión es posible la aplicación de SVM. Es muy utilizado en el procesamiento de lenguaje natural, habla, visión artificial y el reconocimiento de imágenes. SVM se construye a partir de un hiperplano óptimo que se toma como superficie de decisión, de manera que las clases se separan en un margen máximo. Los vectores de soporte hacen referencia a un pequeño subconjunto de las observaciones de entrenamiento que se utilizan como soporte para la ubicación óptima de la superficie de decisión[16].

Por su naturaleza SVM tiene la ventaja de obtener buenos resultados, utilizando pocos datos a diferencia de otras técnicas de inteligencia artificial. En nuestro caso la base de datos cuenta con 130 imágenes adecuadamente etiquetadas las cuales son suficientes para tener datos de entrenamiento y datos de validación. En este trabajo de investigación se propone realizar un informe asistido por computadora basado en el procesamiento digital de imágenes de retina. Nos concentramos en la detección de exudados en la mácula, ya que es un factor importante para el diagnóstico de RD proliferativa, la cual si se desarrolla puede tener consecuencias más severas, como la pérdida de la visión. En una etapa inicial, se realiza el procesamiento de la imagen, en la cual se aíslan exudados duros, para extraer características que pueden ser utilizadas por SVM para determinar su presencia.

Posteriormente, se realiza el aislamiento de vasos sanguíneos, los cuales pueden contribuir a la detección de otras anomalías que se pueden utilizar para realizar el informe.

II. TIPOS DE LESIONES

En la Tabla IV se muestra los 3 principales tipos de lesiones que se pueden tomar en cuenta en la clasificación de la RD de según el grado de afección.

TABLA IV. LESIONES EN RETINA[17]

Nombre	Descripción	Descripción gráfica
Micro-aneurismas	Pequeñas protuberancias en los vasos sanguíneos de la retina que con frecuencia dejan escapar líquidos[8].	
Hemorragias de la retina	Pequeñas manchas de sangre que entran a la retina[10].	
Exudados duros	Es la inflamación o engrosamiento de la mácula a causa de escapes de líquido de los vasos sanguíneos de la retina[3].	

III. SISTEMAS DE DETECCIÓN ACTUALES

A pesar de que la mácula es una pequeña mancha amarillenta en la retina, tiene funciones imprescindibles en la visión del ser humano, tales como conseguir que la visión central del ojo se encuentre en las mejores condiciones posibles, permitir los pequeños detalles (es la encargada de que podamos distinguir rostros y rasgos) así como diferenciar los colores[18].

A. Métodos de obtención de imágenes

El oftalmoscopio directo es un método de examen realizado por el especialista en una habitación. A través de la pupila del oftalmoscopio se ilumina un haz de luz, esto ayuda a que el especialista pueda ver la parte posterior del globo ocular. Otro método utilizado es la angiografía con fluorescencia que permite fotografiar los vasos sanguíneos en la parte posterior del ojo con inyección de tinte para contraste al torrente sanguíneo[13].

La fotografía de fondo de ojo es tomada mediante cámaras digitales midriáticas o no midriáticas, que permiten obtener imágenes nítidas del área macular de la retina, la periferia y el disco óptico. Puede o no necesitar la dilatación de la pupila, dependiendo del ángulo de la foto. En caso de no existir dilatación se pueden tomar fotografías de hasta 45°, las cuales pueden ser suficientes para realizar un informe de las enfermedades más significativas. Un ejemplo de este tipo de cámaras es la Volk Pictor Camera[13].

B. Métodos automatizados

La mayoría de los sistemas automáticos abordan la detección utilizando directamente la forma, el color y el conocimiento del dominio de la diabetes. Las anomalías también pueden detectarse indirectamente al detectar cambios entre dos imágenes de fondo de ojo tomadas del mismo ojo en un momento diferente[13].

El enfoque directo contribuye a la detección de la enfermedad, mientras que el enfoque indirecto contribuye tanto a la detección como a la monitorización de la retinopatía diabética.

Un ejemplo de software automatizado para la detección de retinopatía aprobado recientemente por la FDA diabética (Food and Drug Administration) es un sistema computarizado de lectura de imágenes (IDx-DR) este software mediante un algoritmo analiza imágenes de fondo de ojo tomadas con una cámara Topcon NW400, y permite estadificar estadios de la Retinopatía Diabética por arriba del 85% sin necesidad de un médico evaluador[19].

IV. METODOLOGÍA

En este estudio se usó una base de datos disponible a miembros del IEEE llamada Indian Diabetic Retinopathy Image Dataset (IDRID)[20] la cual consta de un paquete de 130 imágenes de fondo de ojo de 45 grados de 1152X4500 píxeles. En la Figura 1, se describe de manera general los pasos mínimos necesarios para realizar la clasificación de patrones a partir de las imágenes implementando el clasificador basado en SVM.

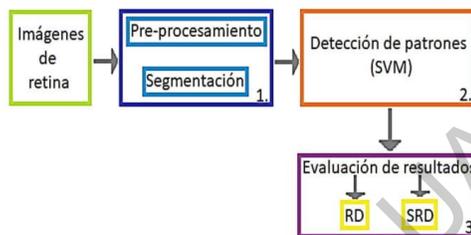


Fig. 1. Metodología Propuesta. Se tiene una imagen de entrada a la que se le aplica la segmentación y procesamiento(1), se aplica el clasificador SVM(2) y el resultado es RD o SRD(3).

1. *Pre-procesamiento y segmentación*: En primera instancia, la imagen tomada de la base de datos es procesada para resaltar los patrones en las zonas de interés.
2. *Detección de patrones*: Una vez que se tenga la imagen con el procesamiento adecuado, así como con la segmentación en las zonas de interés, pasará por el algoritmo de aprendizaje (SVM) previamente entrenado para la detección de los patrones. En este paso se elige una función de kernel.
3. *Evaluación de resultados*: Al tener los resultados, el algoritmo arroja si se tiene (RD) o no (SRD), a partir de la evaluación en los exudados. Al interpretarse los resultados se realiza un informe de estos.

V. PRE PROCESAMIENTO Y SEGMENTACIÓN

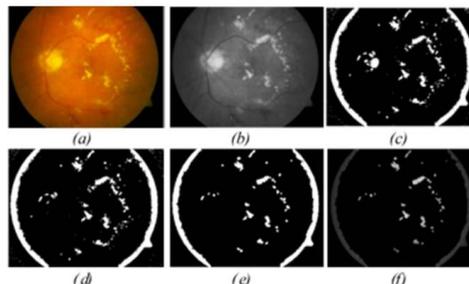


Fig. 2. Detección de exudados duros: (a) Imagen original, (b) Canal verde, (c) Imagen binarizada, (d) Máscara de disco, (e) Procesamiento morfológico, (f) Diferencia de las imágenes d y e.

A. Exudados duros

En la Fig. 2 se muestra la detección de exudados duros. Para obtener los exudados, que es la zona de interés deseada, se descompone la imagen original Fig. 2(a) en los canales RGB para así tomar únicamente la componente en G Fig. 2 (b), esto debido a que este canal es el que nos ofrece una mayor información de la imagen para segmentar los exudados. El canal verde se binariza Fig. 2(c) y posteriormente se aplica una 'Máscara del disco óptico' Fig. 2(d) (Esta máscara es explicada en el inciso B), ya que el disco óptico posee un color similar al de los exudados, como se puede ver en la Fig 2(a), por lo que al aplicar esta máscara se borra de la imagen dicho disco. Prosiguiendo con la segmentación se utilizan operaciones morfológicas Fig. 2 (e) (dilatación, erosión, abrir) que ayuden a la reducción del ruido en la imagen. Finalmente se hace una diferencia de la imagen

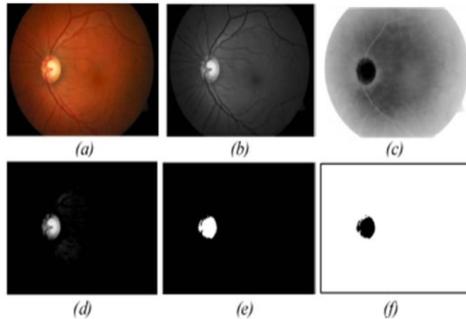


Fig. 3. Disco óptico: (a) Imagen original, (b) Canal verde (c) Canal cyan, (d) Diferencia de las imágenes b y c, (e) Binarización, (f) Complemento de la imagen e.

B. Máscara del Disco Óptico

En la Fig. 3 se describen los pasos para realizar la máscara del disco o nervio óptico. Para realizar esta máscara, la imagen original Fig. 3(a) se descompone en los canales RGB y solo se aísla el canal verde Fig. 3 (b) que es el canal que resalta de mejor manera la parte del disco óptico. La imagen original RGB se cambia a la paleta CMY y de esta se toma solo el canal cyan Fig. 3 (c) que oscurece la parte del disco óptico. Se realiza una diferencia de los canales verde y cyan Fig. 3 (d), por lo que obtenemos una imagen casi en dos tonalidades donde se puede percibir que resalta la característica buscada. Se binariza la imagen obtenida de la diferencia Fig. 3 (e) y por último se realiza el complemento Fig. 3(f) de la binarización, resultando una máscara del tamaño del disco óptico, que nos permitirá cubrirlo por completo para que en la segmentación de exudados duros no se confunda.

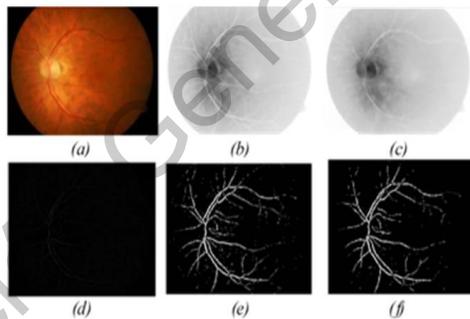


Fig. 4. Vasos Sanguíneos: (a) Imagen original, (b) Componente cyan, (c) Procesamiento morfológico, (d) Diferencia de las imágenes b y c, (e) Binarización, (f) Reducción de ruido.

C. Vasos Sanguíneos

La Fig. 4, muestra el proceso que se lleva para resaltar los vasos sanguíneos del ojo en un fondo negro. La imagen Fig. 4(a) es la imagen original tomada directamente de la base de

datos, esta imagen se pasa de RGB a los componentes CMY para aislar únicamente la componente cyan Fig. 4(b). Se aplican operaciones morfológicas para el tratamiento de la imagen (erosión, abrir, dilatación) Fig. 4(c), a continuación, se realiza una diferencia entre las imágenes Fig. 4(b) y Fig. 4(c). El resultado es una imagen un tanto oscura Fig. 4(d) en la que con dificultad se pueden notar las venas oculares a simple vista, por lo que se binariza con el objetivo de resaltarlas en blanco Fig. 4(e). Y por último para reducir el ruido en la imagen se aplica un filtro gaussiano Fig. 4(f).

Es así como mediante el procesamiento y segmentación de las imágenes podemos resaltar las características que se ocupan para el estudio en curso.

VI. CLASIFICADOR

Para obtener los mejores resultados en el entrenamiento se deben resaltar las características relevantes en las imágenes, es por eso que el procesamiento y la segmentación se llevaron a cabo en las imágenes de fondo de ojo aislando solo los exudados presentes. Para esta etapa se aplica un clasificador SVM, este clasificador es usado para evaluar los datos de entrenamiento y dividir en casos como Sin Retinopatía Diabética (SRD) y con Retinopatía Diabética (RD), es decir hay exudados presentes o están ausentes en las imágenes.

SVM es un clasificador discriminativo que se caracteriza formalmente por el uso de un hiperplano de separación o aislamiento [22]. El proceso de preparación de SVM consiste en que, a partir de las imágenes de entrenamiento, para localizar un enfoque idóneo, se agrupan las imágenes en las clases existentes, SRD y RD. Los parámetros de disposición se determinan mediante el aprendizaje automático por vectores de soporte.

Para ajustar las curvas no lineales a la información, el SVM hace uso de la capacidad de una parte para delinear la información en un espacio alternativo donde un hiperplano podría ser usado para hacer la partición. En este trabajo se realiza un primer entrenamiento con un SVM lineal [23] y para fines de comparación usamos un kernel gaussiano [23] en un segundo entrenamiento.

El clasificador SVM se prepara con 104 imágenes de fondo de ojo (80% de los datos), para el entrenamiento que muestran exudados evidentes o ausentes, y 26 imágenes (20% de los datos) se utilizan para la validación.

VII. RESULTADOS

Los resultados obtenidos en este estudio bajo las condiciones antes explicadas se muestran a continuación.

De las 130 imágenes con que cuenta la base de datos, 73 de ellas están etiquetadas como 'ojos sanos' o sin exudados y los 57 restantes son 'lesiones presentes' o exudados evidentes. En la Tabla V, se muestra un resumen de los resultados para cada método aplicado, un SVM de función lineal y un SVM aplicando con un kernel gaussiano. El mejor desempeño fue adquirido usando una clasificación binaria de SVM con función de núcleo lineal.

TABLA V. RESULTADOS OBTENIDOS

	SVM	SVM (kernel gaussiano)
Precisión	92.4%	80.8%
Sensibilidad	87.3%	82.1%
Especificidad	84.6%	66.2%

VIII. CONCLUSIÓN

Se han presentado algoritmos eficientes para el aislamiento de exudados duros y vasos sanguíneos a partir de procesamiento y segmentación de imágenes. Las características propuestas muestran un gran potencial para la detección y clasificación de RD. SVM puede detectar la RD con una sensibilidad de casi el 90%, mientras que se puede clasificar con una exactitud del 92%. SVM constantemente muestra mejores resultados que otros algoritmos de aprendizaje automático. Podemos concluir que el procesamiento de imágenes retina tiene el potencial de desempeñar un papel importante en el diagnóstico de la retinopatía diabética. Los resultados son alentadores y una futura evaluación clínica integrará los algoritmos presentados en una herramienta realizar informes de la retinopatía. Otros trabajos futuros son la detección de micro-aneurismas y hemorragias, además de los exudados duros y los vasos sanguíneos, para mejorar la precisión y la sensibilidad de nuestro detector de retinopatía.

IX. REFERENCIAS

- [1] D. De Postura, C. A. A. Salinas, S. Hernández Jiménez, M. Hernández, Á. Juan, and E. H. Ávila, "ACCIONES PARA ENFRENTAR A LA DIABETES."
- [2] "La Retinopatía Diabética se convertirá en la principal causa de baja visión en México - Federación Mexicana de Diabetes." [Online]. Available: <http://fndiabetes.org/la-retinopatia-diabetica-se-convertira-la-principal-causa-baja-vision-mexico/>. [Accessed: 17-May-2019].
- [3] S. Zachariah, W. Wykes, and D. Yorston, "Grading diabetic retinopathy (DR) using the Scottish grading protocol," *Community Eye Heal. J.*, vol. 28, no. 92, pp. 72–73, 2015.
- [4] "¿Qué es un edema macular? - American Academy of Ophthalmology." [Online]. Available: <https://www.aaopt.org/salud-ocular/enfermedades/edema-macular>. [Accessed: 17-May-2019].
- [5] Q. Dong, S. Gong, and X. Zhu, "Imbalanced Deep Learning by Minority Class Incremental Rectification," *IEEE Trans. Pattern Anal. Mach. Intell.*, pp. 1–14, 2018.
- [6] H. He and E. Garcia, "Learning from imbalanced data," *Ieee Trans. Knowl. Data Engin.*, vol. 21, no. 9, pp. 1263–1284, 2009.
- [7] R. Geetha Ramani, B. Lakshmi, and S. G. Jacob, "Data mining method of evaluating classifier prediction accuracy in retinal data," 2012 *IEEE Int. Conf. Comput. Intell. Comput. Res. ICCIC 2012*, pp. 1–4, 2012.
- [8] I. Lazar and A. Hajdu, "Retinal microaneurysm detection through local rotating cross-section profile analysis," *IEEE Trans. Med. Imaging*, vol. 32, no. 2, pp. 400–407, 2013.
- [9] "Introducing Deep Learning with MATLAB."
- [10] T. P. Karnowski et al., "Textureless Macula Swelling Detection With Multiple Retinal Fundus Images," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 3, pp. 795–799, 2010.
- [11] M. Gandhi and R. Dhanasekaran, "Diagnosis of diabetic retinopathy using morphological process and SVM classifier," *Int. Conf. Commun. Signal Process. ICCSP 2013 - Proc.*, pp. 873–877, 2013.
- [12] P. R. and A. P., "Diagnosis of Diabetic Retinopathy Using Machine Learning Techniques," *ICTACT J. Soft Comput.*, vol. 03, no. 04, pp. 563–575, 2015.
- [13] admin, "Detection of Diabetic Retinopathy Using Support Vector Machine _SVM_," *Int. J. Emerg. Technol. Comput. Sci. Electron.*, vol. 23, pp. 976–1353.
- [14] D. Ning and L. Yafen, "Automated Identification of Diabetic Retinopathy Stages Using Support Vector Machine."
- [15] L. Xu and S. Luo, "Support vector machine based method for identifying hard exudates in retinal images," *Proc. - 2009 IEEE Youth Conf. Information, Comput. Telecommun. YC-ICT2009*, no. 10, pp. 138–141, 2009.
- [16] O. Chapelle, P. Haffner, and V. N. Vapnik, "Support vector machines for histogram-based image classification," *IEEE Trans. Neural Networks*, vol. 10, no. 5, pp. 1055–1064, 1999.
- [17] "Diabetic Retinopathy Detection | Kaggle." [Online]. Available: <https://www.kaggle.com/c/diabetic-retinopathy-detection>. [Accessed: 30-Mar-2019].
- [18] H. S. V. Kumar, B. Pt, and R. Madhuri, "A Novel Method for Image Analysis and Exudates Detection in Retinal Images," vol. 4, no. 1, pp. 219–223, 2016.
- [19] "La FDA permite la comercialización de un dispositivo con inteligencia artificial para detectar ciertos problemas oculares relacionados con la diabetes | FDA." [Online]. Available: <https://www.fda.gov/news-events/comunicados-de-prensa/la-fda-permite-la-comercializacion-de-un-dispositivo-con-inteligencia-artificial-para-detectar>. [Accessed: 17-May-2019].
- [20] P. Porwal et al., "Indian Diabetic Retinopathy Image Dataset (IDrID): A Database for Diabetic Retinopathy Screening Research," 2018.

16.4 Constantia de Acreditación de Lengua



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO FACULTAD DE LENGUAS Y LETRAS



A QUIEN CORRESPONDA:

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

CISNEROS GUZMAN MARIA FERNANDA

Presentó el **Examen de Manejo de la Lengua** efectuado el día veintiuno de mayo de dos mil diecinueve, en el cual obtuvo la siguiente calificación:

8-

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veintiocho de mayo de dos mil diecinueve.

Atentamente,
"Enlazar Culturas por la Palabra"



LIC. LAURA PÉREZ TÉLLEZ

LPT/evm*CL*FLL-C.-302



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro.
C.P. 76140, Tel. 01 (442) 192 12 00 Dirección Ext. 61010,
Secretaría Administrativa 61300, Posgrado 61140, Licenciatura 61070,
Centro de Lenguas 61050, Secretaría Académica 61100 y Planeación 61110

SOMOS UAQ
EDUCAR CRECER CONSOLIDAR



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE LENGUAS Y LETRAS



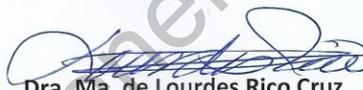
Campus Aeropuerto, 03 de julio de 2019.
FLL/SA/HCA/2019/499

C. Cisneros Guzmán, María Fernanda
Exp. 201927
Facultad de Ingeniería
Presente.

Me permito comunicar a usted que en Sesión Ordinaria del H. Consejo Académico de la Facultad de Lenguas y Letras, celebrada el **03 de julio de 2019**, se acordó **Aprobar** su solicitud de **convalidación** de la Constancia del Examen de Manejo de la Lengua (8-), expedida por el CELYC, por **Examen de Comprensión de Textos en Inglés**.

Sin más por el momento, me es grato quedar a sus órdenes para cualquier aclaración.

Atentamente,
"Enlazar Culturas por la Palabra"


Dra. Ma. de Lourdes Rico Cruz
Secretaría Académica



**SECRETARÍA
ACADÉMICA**

C.c. Expediente.
Archivo.

MLRC/**mlp

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro.
C.P. 76140, Tel. 01 (442) 192 12 00 Dirección Ext. 61010,
Secretaría Administrativa 61300, Posgrado 61140, Licenciatura 61070,
Centro de Lenguas 61050, Secretaría Académica 61100 y Planeación 61110

SOMOS UAQ
EDUCAR CRECER CONSOLIDAR