

Diagnóstico de retinopatía diabética en imágenes digitales mediante máquinas de vectores de soporte

José Francisco Delgado-Orta¹ , Alicia Adriana Clemente-Hernández¹Jorge Ochoa-Somuano^{1*}  & María Alejandra Menéndez-Ortiz¹ 

Resumen

El diagnóstico de retinopatía diabética es un problema complejo, abordado por la medicina y la informática, mediante técnicas como el procesamiento digital de imágenes y los algoritmos de aprendizaje automático. Los métodos tradicionales de diagnóstico sugieren la adquisición de las imágenes de fondo de ojo de pacientes a quienes se les practican métodos invasivos para resaltar las características de la retina. En ese sentido, los especialistas observan la existencia de tres patrones que sirven como base en los estudios de retinopatía diabética: la deformación de los glóbulos rojos, la aparición de exudados y los aneurismas. Sin embargo, la dificultad en la interpretación de la información de las imágenes, ha representado un reto para los especialistas de las áreas médicas y ha dificultado la producción de herramientas informáticas confiables. Este trabajo presenta una aproximación inicial para la solución del problema, basada en extracción de características en imágenes de la retina de personas sanas y personas con retinopatía diabética, las cuales son procesadas por un clasificador de máquinas de vectores de soporte con la finalidad de producir una herramienta capaz de identificar a pacientes sanos y a pacientes con el padecimiento. Estudios experimentales muestran una eficiencia del 56% en el diagnóstico y del 54% en la detección (a priori) del padecimiento, esto representa un área de oportunidad para mejorar el clasificador, así como la apertura hacia la implementación de métodos computacionales alternativos, en vías de asegurar una alta confiabilidad en la herramienta para su aplicación en el sector salud.

Palabras clave: retinopatía diabética, imágenes de fondo de ojo, máquinas de vectores de soporte, vasos sanguíneos, microaneurismas.

Abstract

The diagnosis of diabetic retinopathy is a complex problem, addressed by both medicine and computer science, through techniques such as digital image processing and machine learning algorithms. Traditional diagnostic methods suggest the acquisition of fundus images of patients, using invasive procedures to highlight the features of the retina. In this regard, specialists identify three patterns that serve as a basis for studies on diabetic retinopathy: red blood cell deformation, the presence of exudates, and aneurysms. However, the difficulty in interpreting image information has posed a challenge for medical specialists and has hindered the development of reliable computational tools. This work presents an initial approach to addressing the problem, based on feature extraction from retinal images of both healthy individuals and patients with diabetic retinopathy, which are processed by a Support Vector Machine classifier with the aim of producing a tool capable of distinguishing between healthy patients and those with the condition. Experimental studies show an efficiency of 56% in diagnosis and 54% in the (a priori) detection of the condition. This represents an opportunity for improving the classifier, as well as the openness toward the implementation of alternative computational methods, in order to ensure high reliability of the tool for its application in the healthcare sector.

Keywords: diabetic retinopathy, eye fundus images, support vector machine, blood vessels, microaneurysms.

Recibido: 05 de marzo de 2025.

Aceptado: 04 de septiembre de 2025.

¹ Instituto de Industrias, Universidad del Mar campus Puerto Escondido. Carretera Federal Puerto Escondido - Sola de Vega, Puerto Escondido 71980, Oaxaca, México.

* Autor de correspondencia: ochoa@zicatel.umar.mx (JOS)

Introducción

La retinopatía diabética (RD) es una complicación de la diabetes que afecta a los ojos. A nivel mundial, la IDF (International Diabetes Federation) estima que en 2019 existían 463 millones de personas diagnosticadas con diabetes. Este organismo pronosticó que para el año 2030, existirán 578 millones de personas con la enfermedad, por lo que se espera que esta cifra aumente significativamente en las próximas décadas (INEGI 2021a).

México cuenta con 305,418 personas ocupadas como médicos, donde por cada 100 médicos, 67 son médicos generales y 33 especialistas (INEGI 2021b). La proporción existente de médicos generales con respecto a la población total nacional es de 2.4 especialistas por cada mil habitantes, la cual resulta es insuficiente, dada la recomendación de la OCDE de contar con por lo menos 3.4 médicos por cada mil habitantes (Sandoval 2020). En el caso de los oftalmólogos (expertos en RD), estos muestran una proporción menor, estimándose en un rango de 29.8 a 52.2 por cada millón de habitantes (Resnikoff *et al.* 2020).

En el año 2023, el Sector Salud reportó a 12.4 millones de personas diagnosticadas con diabetes tipo 1 y tipo 2, de las cuales, el 10% llega a presentar la pérdida de la visión; y en el caso de la diabetes tipo 2, esta cifra aumenta a uno de cada tres pacientes (IMSS 2023). En ese sentido, la insuficiencia de especialistas y la proliferación estimada del padecimiento dificultan su detección, diagnóstico, atención y tratamiento oportunos cuando este se manifiesta en una etapa temprana, como consecuencia de la evolución de la diabetes.

La detección de RD consiste en la aplicación de un examen médico

denominado fondo de ojo, cuyo principal cometido es la identificación de patrones de la retina. En la actualidad, en los centros de salud el oftalmólogo realiza un examen de fondo de ojo, donde se dilatan las pupilas mediante gotas midriáticas, lo que permite observar la retina con un mayor nivel de detalle a través de una lente especial, a la cual se conecta una cámara que toma fotografías de la retina en un escenario con una iluminación tenue en tiempo estimado de diez minutos, en el que la tinta de las gotas se traslada a través de los vasos sanguíneos.

Posteriormente, las imágenes recopiladas son analizadas por el oftalmólogo, quien comúnmente se apoya de herramientas computacionales basadas en el Procesamiento Digital de Imágenes (PDI), así como de algoritmos de Inteligencia Artificial para efectuar el diagnóstico (esto ocurre cuando el padecimiento es visible y el paciente ya manifiesta daños en la retina), o bien, la detección del padecimiento cuando los daños en la retina comienzan a manifestarse a causa de la diabetes.

De esta forma, el procesamiento de imágenes de fondo de ojo permite caracterizar las imágenes, permitiendo que las características extraídas muestren la aparición de los patrones relacionados con los daños a causa de la enfermedad, razón por la cual, una detección temprana del padecimiento permitiría suministrar los tratamientos adecuados a los pacientes, para evitar la pérdida de la visión en el corto plazo.

Esta problemática ha sido estudiada mediante diversos enfoques de solución, en la búsqueda de un diagnóstico eficiente, mediante la definición de diversas fases de caracterización de la retina que son parte del procesamiento digital de imágenes aplicado en estudios de oftalmología.

Estas fases han permitido identificar cuatro componentes característicos que se presentan en una prueba de fondo de ojo para un paciente con RD: los vasos sanguíneos (dilatados o con un crecimiento anormal), los exudados, las hemorragias y los microaneurismas, siendo estos el objeto de estudio de diversos trabajos relacionados.

Una vez que estos componentes han sido caracterizados, las metodologías existentes para la diagnosis suelen emplear algoritmos típicos de clasificación como el de los k-vecinos más cercanos, aquellos basados en redes bayesianas, de regresión o como el caso de las máquinas de vectores soporte. Estos métodos han permitido categorizar cada pixel de las imágenes de fondo de ojo en términos de células “sanas” o células “lesionadas” a causa del padecimiento.

En propuestas como la abordada en Wisaeng *et al.* (2012) se implementan nuevos enfoques para el reconocimiento de las patologías de los exudados en la RD, mediante pruebas en entornos alimentados con diferentes espacios de color, basados en la selección del Luv (Al-Hazaimah *et al.* 2022) identificada por los oftalmólogos como la más apropiada para la separación de clases en los píxeles de la imagen que presentan exudados y no exudados. El trabajo emplea también un método de selección de características y una técnica para la clasificación, destacándose en este último caso el algoritmo FCM (*Fuzzy C-Means*), en combinación con técnicas de reconstrucción morfológica (MR o *Morphological Reconstruction*).

Al mismo tiempo, el enfoque presentado en (Al-Hazaimah *et al.* 2022) documenta una mejora sustancial en la clasificación de los exudados, los microaneurismas y las hemorragias en la retina a través de diversas etapas de preprocesamiento, tales

como la conversión HSI (Tono, Saturación e Intensidad), la eliminación de ruido, así como otras etapas intermedias. Este preprocesamiento es complementado mediante el uso de clasificadores híbridos, como el SVMGA (*Support Vector Machine Genetic Algorithm*) que es una combinación entre las máquinas de vectores de soporte (SVM o *Support Vector Machine*) y las Redes Neuronales Probabilistas (PNN o *Probabilistic Neural Network*), obteniendo con ello una mayor precisión, eficiencia y efectividad en los experimentos reportados.

Trabajos recientes han abordado también algoritmos de aprendizaje máquina (ML o *Machine Learning*) para la predicción de la RD mediante la aplicación de técnicas como la visión por computadora, análisis médicos, redes neuronales artificiales, entre otros sistemas de detección (Sahlsten *et al.* 2019, Oh *et al.* 2021), los cuales permiten la extracción de características de aquellos atributos más significativos para emplear sobre estos algoritmos que realicen el análisis exhaustivos como los enfoques de aprendizaje profundo (*deep learning*), en la búsqueda de patrones de aprendizaje automático en los conjuntos de entrenamiento y de prueba (Uppamma *et al.* 2023).

La diversidad existente de enfoques en las tareas del PDI permiten producir metodologías robustas que permitan probar y mejorar la eficiencia y precisión de los métodos documentados, así como de adaptar las técnicas de ML para diversos contextos.

Materiales y métodos

El diagnóstico de RD que se propone en este trabajo se basa en el esquema de ocho etapas propuesto en (Malhi 2023), que se

establece de acuerdo con el esquema de la figura 1. En primera instancia, se selecciona un repositorio de imágenes disponible en la literatura con imágenes con distintos grados de RD; posteriormente, se efectúa un muestreo, en el cual se obtienen las imágenes de fondo de ojo con pacientes diagnosticados tanto con resultado

positivo como negativo al padecimiento. Estas imágenes son ingresadas a la etapa de Preprocesamiento, en donde se filtran con el objetivo de obtener sus características, etiquetando con ello los componentes característicos de la RD.

Una vez que se han identificado los componentes característicos, se selecciona

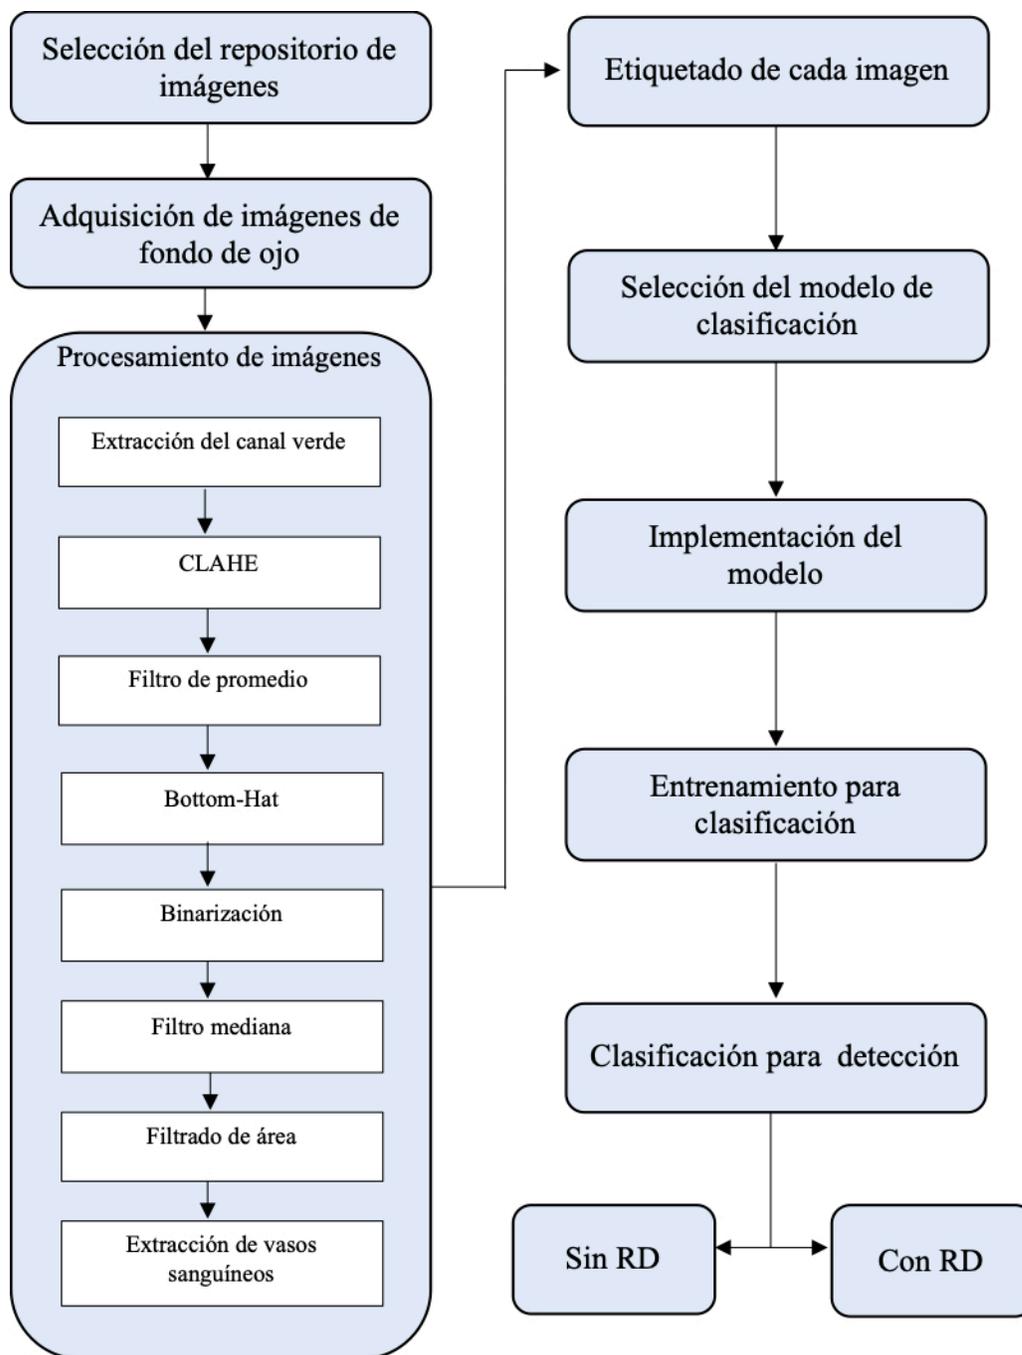


Figura 1. Metodología de solución.

y se implementa el modelo de clasificación para el diagnóstico, para posteriormente invocar las etapas de entrenamiento y prueba, etapas a partir de las cuales es posible determinar las clases “con RD” y “Sin RD”, siendo estas el resultado del diagnóstico.

Selección del repositorio de imágenes. En esta etapa se obtuvieron imágenes de fondo de ojo de un repositorio público, de acuerdo con las guías *Sex and Gender Equity in Research (SAGER)*, relacionadas con la identificación de hombres y mujeres mediante investigación biométrica (Heidari *et al.* 2018), dada la calidad y diversidad de las imágenes que son parte de su contenido.

Adquisición de imágenes. Para preparar los conjuntos de datos de entrenamiento y de prueba, se recolectan imágenes de fondo de ojo de pacientes con RD y sin RD del repositorio seleccionado, lo que permite emplear las técnicas de ML para caracterizar las imágenes e identificar los patrones para los cuatro componentes de la RD.

Preprocesamiento de las imágenes. Consta de siete etapas de filtrado: la extracción del canal verde, el cálculo del histograma de ecualización adaptativo de contraste limitado (CLAHE o *Contrast Limited Adaptive Histogram Equalization*), el suavizado, una operación morfológica, la binarización, el filtro de la mediana y el filtrado de área. Estas etapas se ejecutan en secuencia para eliminar el ruido y mejorar la calidad de las imágenes adquiridas, produciendo imágenes preprocesadas que destacan las características principales y resaltan los rasgos significativos que identifican a la enfermedad: los microaneurismas, los exudados y los derrames oculares. Las funcionalidades particulares de estos filtros se definen a continuación:

i) *Extracción del canal verde:* consiste en la aplicación del patrón RGB (Red-Green-Blue) sobre la imagen, eliminando los rasgos de color de los canales rojo (R) y azul (B) y extrayendo únicamente el canal verde (G), ya que es aquel en el que se conoce la existencia de una menor saturación, en comparación con los canales R o B. El canal verde presenta una iluminación adecuada y diferentes variaciones de intensidad, lo que permite identificar zonas de interés en la imagen que no son visibles con el filtrado de las combinaciones RGB.

ii) *CLAHE:* permite mejorar el contraste de la imagen, detectando los microaneurismas presentes, por lo cual, un contraste adecuado es funcional para las etapas siguientes en el proceso.

iii) *Suavizado:* aplica el filtro del promedio para reducir las variaciones de las intensidades entre píxeles.

iv) *Operación morfológica:* se emplea para extraer los objetos más pequeños y oscuros en las imágenes, mediante el filtro Bottom-Hat.

v) *Binarización y filtro de la mediana:* empleados para segmentar las imágenes, lo que permite detectar lesiones; y posteriormente, el filtro de la mediana elimina el ruido que pueda afectar la información.

vi) *Filtrado de área:* permite extraer los grandes vasos sanguíneos conectados, lo que es relevante para que se logre una clasificación eficiente (Malhi 2023).

Las imágenes obtenidas la aplicación de las siete etapas de filtrado son empleadas para el etiquetado “con RD” y “sin RD” para posteriormente ser turnadas al clasificador.

Etiquetado de cada imagen. En esta etapa se resaltan las regiones de interés en las

imágenes preprocesadas, que denotan la presencia o ausencia de anomalías de RD en términos de los cuatro componentes característicos de la RD (Fig. 2), con la finalidad de extraer los patrones para el entrenamiento y la validación del modelo.

Selección del modelo de clasificación. La elección del modelo de aprendizaje para los patrones de la RD se basa en tres métricas, presentadas en Al-Hazaimeh *et al.* (2022), para evaluar la precisión (Accuracy), la especificidad (Specificity) y la sensibilidad (Sensitivity) de los datos de las imágenes etiquetadas.

Para ello, se contabilizan las frecuencias de los casos en los que los pacientes con retinopatía diabética son correctamente identificados por el clasificador. Estos se denominan verdaderos positivos (TP o *True Positives*). De igual manera, los pacientes que no presentan retinopatía diabética y

que son correctamente clasificados como sanos se consideran verdaderos negativos (TN o *True Negatives*).

Por otro lado, la frecuencia de falsos positivos (FP o *False Positives*) corresponde a aquellos casos en los que el clasificador identifica incorrectamente como enfermos a pacientes que no padecen retinopatía diabética. Y finalmente, la frecuencia de falsos negativos (FN o *False Negatives*) se refiere a los pacientes que sí presentan la enfermedad, pero que el clasificador clasifica erróneamente como sanos.

Estos parámetros se utilizan para el cálculo de las métricas, de acuerdo con lo establecido en las ecuaciones (1)-(3).

$$\text{Ec. 1} \quad \text{Precisión} = \frac{TN+TP}{TN+TP+FN+FP}$$

$$\text{Ec. 2} \quad \text{Especificidad} = \frac{TN}{TN+FP}$$

$$\text{Ec. 3} \quad \text{Sensibilidad} = \frac{TP}{TP+FN}$$

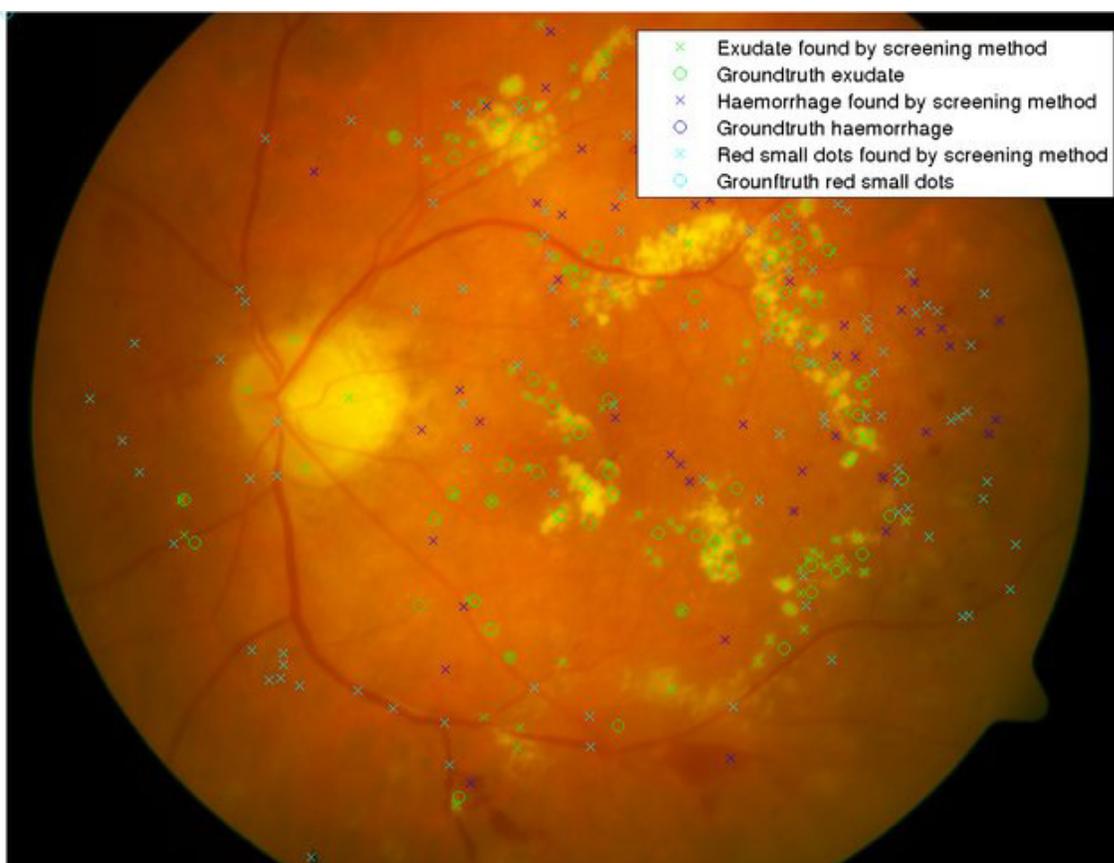


Figura 2. Etiquetado de componentes característicos (tomada de Stella Mary *et al.* 2016).

La Ec. 1 calcula la precisión como el cociente de la suma de los coeficientes de los diagnósticos clasificados correctamente sobre la sumatoria de todos los ejemplos clasificados. Del mismo modo, la Ec. 2 calcula la especificidad como el resultado de la división de los ejemplos clasificados correctamente con ausencia de RD sobre la sumatoria de las frecuencias de los pacientes sin RD y aquellos que fueron clasificados con RD, aun cuando no la padecen. De la misma forma, la sensibilidad se calcula aplicando el cociente de la Ec. 3, donde el resultado se expresa como una relación de los pacientes clasificados con RD sobre las frecuencias acumuladas de pacientes con RD y aquellos que fueron diagnosticados con RD, considerando que no la padecen. Estas métricas permiten medir la eficiencia de los algoritmos de clasificación, con lo cual, se puede concluir que estos son viables para ser llevados a escenarios de implementación.

Implementación del modelo. En esta etapa se configuran los parámetros que permiten la clasificación de las imágenes etiquetadas, lo cual es llevado a cabo mediante el clasificador SVM (Data Science Team 2020). Los parámetros empleados por este clasificador son: a) Un valor entero C , que controla la penalización por clasificación incorrecta, el cual, mantiene el equilibrio de la precisión entre el conjunto de entrenamiento y la generalización de aquellos ejemplos no contemplados; b) un valor real Γ , que define el grado de influencia para cada ejemplo de entrenamiento; donde un valor alto ajusta la salida a los datos de entrenamiento; sin embargo, podría brindar un rendimiento deficiente en datos no clasificados; y c) un identificador Kernel de tipo cadena de caracteres, empleado para efectuar el mapeo de los

datos originales de entrada hacia espacios vectoriales con características de mayor dimensión. Los tipos de kernel conocidos para la SVM son: el lineal, el polinomial, el radial y el sigmoideal. El ajuste de estos parámetros es esencial para entrenar el clasificador con las imágenes etiquetadas, lo que permite evaluar la eficiencia en la detección del padecimiento.

Identificación de RD (entrenamiento y prueba). En esta etapa, el modelo aprende de las imágenes etiquetadas los patrones que localizan las anomalías y considera la posibilidad de presencia de RD. Para ello, se definen dos escenarios de prueba. El primer escenario considera 40 imágenes del repositorio, seleccionadas con base en un muestreo aleatorio, de las cuales se considera un 50% que presentan RD y el otro 50% con ausencia de RD para la etapa de entrenamiento, mientras que para la fase de prueba se utilizó el 20% de las imágenes de cada clase. En el segundo escenario se aplica un muestreo de 30 imágenes del repositorio, de las cuales, el 50% presentan RD y el otro 50% están ausentes de RD, empleando para las pruebas el 30% de las imágenes de cada clase.

Detección de RD. Una vez entrenado el modelo, el clasificador determina la presencia o ausencia de RD con base en los patrones aprendidos durante el entrenamiento. Una característica relevante de la SVM implementada en el clasificador, establecida en (Raj S *et al.* 2023), consiste en la extracción de características de una imagen mediante sus píxeles, lo que permite al algoritmo localizar los patrones y dividir la imagen en un espacio de clases disjuntas, algo que se efectúa en la etapa de etiquetado. Para ello se emplea la imagen etiquetada, que es almacenada en los vectores $x_{train_normalizada}$ y $x_{test_normalizada}$,

Tabla I. Algoritmo ClasificadorRD; permite clasificar las imágenes en clases ya sea por presencia o ausencia de Retinopatía Diabética.

1	Algoritmo ClasificadorRD(SVM, Metricas, x_train_normalizada, y_train_normalizada)
2	SVM(Metricas.precision, x_train_normalizada, y_train)
3	SVM(Metricas.precision, x_test_normalizada, y_test)
4	y_pred = SVM.predict(x_test_normalizada)
5	imprimir(Metricas.matriz_de_confusion(y_test, y_pred))
6	Fin Algoritmo ClasificadorRD

produciendo como salida y_{train} para el entrenamiento y y_{test} para las pruebas, evaluando el desempeño del algoritmo y definiendo la métrica de clasificación, de acuerdo con el algoritmo definido en la tabla I.

El algoritmo de la tabla I define la ejecución del clasificador, en términos del establecimiento del clasificador SVM (línea 2), el cual, implementa la métrica de precisión, produciendo como salida el vector de respuesta y_{train} a partir del vector de características $x_{train_normalizada}$. Luego, en la línea 3 se invoca el procedimiento de prueba del clasificador, recibiendo como entrada el vector $x_{test_normalizada}$ y produciendo como salida el vector y_{test} . En la línea 4, se aplica un método predictivo (llamada al método predict de la SVM) a partir del modelo de entrenamiento, el cual recibe el vector $x_{test_normalizada}$, y produce como salida el vector y_{pred} , que permite producir la matriz de confusión (línea 5) para los vectores y_{test} y y_{pred} . Una vez que se implementa el algoritmo ClasificadorRD, este se utiliza para evaluar el desempeño del diagnóstico, el cual es visible mediante la impresión de la matriz de confusión (línea 6), a partir de la cual se pueden obtener las estadísticas de rendimiento del clasificador y las relaciones de las frecuencias que son parte de las métricas del problema.

Pruebas y resultados

Las pruebas y entrenamiento se efectuaron con el conjunto de datos de imágenes de fondo de ojo extraídas de la plataforma Kaggle, Aptos 2019 dataset (Aptos dataset 2019). Este conjunto de datos cuenta con 2930 imágenes de ojos agrupadas en imágenes de prueba (*test_images*) y de entrenamiento (*train_images*), de las cuales no existe una separación entre vistas de ojos sanos y ojos enfermos. Observando el inconveniente de esta mezcla de las imágenes, se desarrolló un algoritmo que permitiera realizar esta clasificación, concentrando esta información en un archivo de texto plano con delimitadores (.csv) e identificando del repositorio cinco categorías para la RD: sin RD, RD leve, RD moderada, RD severa y RD proliferativa, de las cuales se determinó la existencia de 1434, 300, 808, 154 y 234 imágenes respectivamente. Para este trabajo se seleccionó la métrica de precisión para medir el desempeño del clasificador para dos clases: la primera como “con RD”, que comprende los casos leve, moderada, severa y proliferativa; y la segunda como “sin RD”, como primera aproximación, en términos de los cuatro indicadores definidos para la selección del modelo relacionado (TP, FP, FN y TN). El preprocesamiento (Fig. 3) implementa las transformaciones para la imagen original (3.a) los filtros del canal verde (3.b), CLAHE (3.c), suavizado (3.d), operación

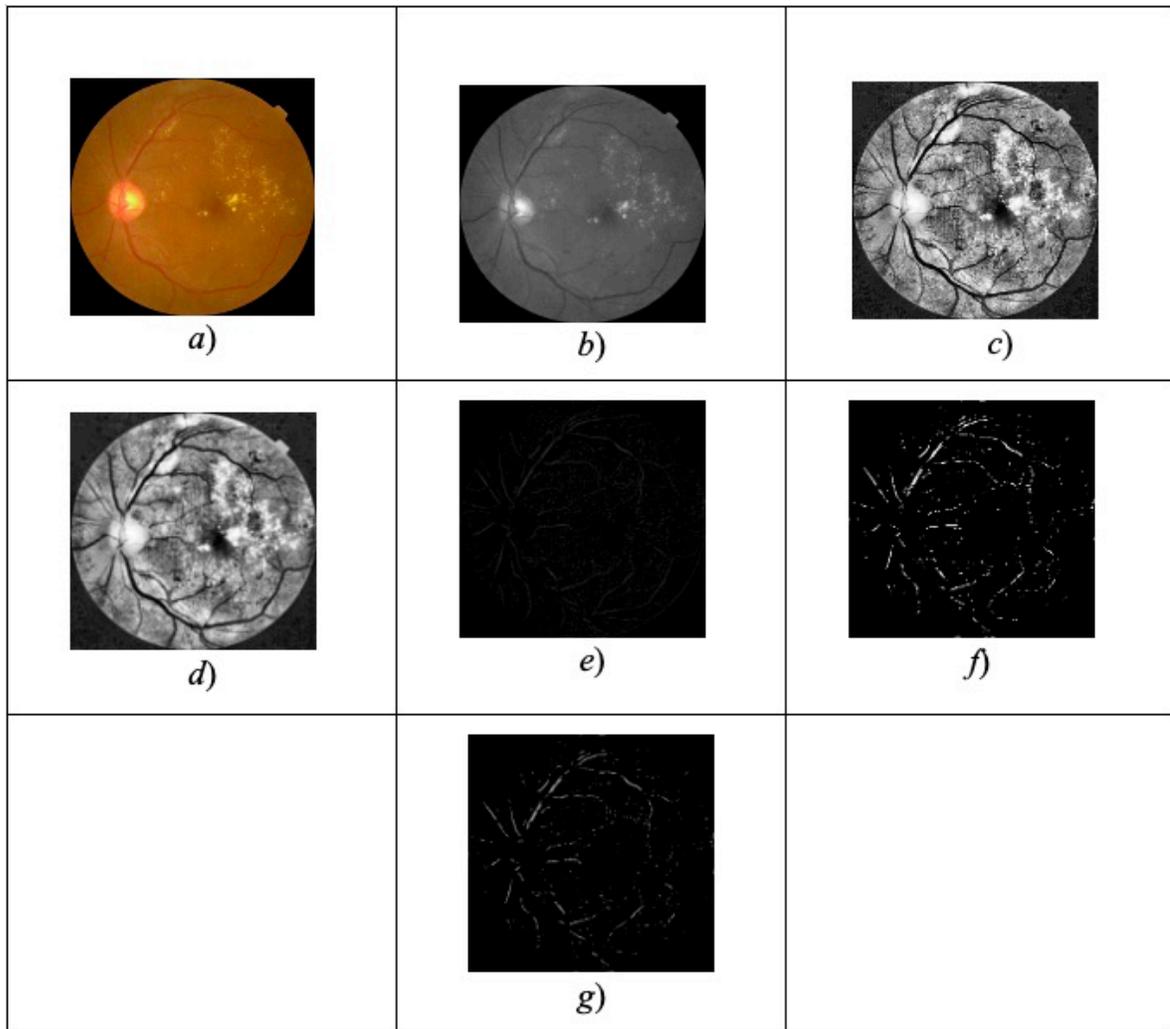


Figura 3. Procesamiento de las imágenes.

morfológica (3.e), el de umbralización y reducción de ruido (3.f) y el de la mediana (3.g), con el objetivo de detectar si el modelo de clasificación implementado es capaz de diferenciar las características de las clases “con RD” y “ausente de RD”. La SVM se probó con el kernel “radial”, debido a la característica “no linealmente separable” observada en los valores de los vectores característicos de las imágenes preprocesadas, aspecto que es también soportado por Pedregosa (2011). Los resultados de la métrica de eficiencia para los escenarios de entrenamiento y prueba se muestran en la tabla II.

El rendimiento del clasificador con los conjuntos de imágenes definidos para el

entrenamiento y las pruebas observaron una precisión para la SVM implementada del 56.2% y 54.5%, respectivamente. Los datos de la tabla II muestran que en la primera prueba, la matriz de confusión indica que dos imágenes se clasifican con presencia de RD y seis imágenes con presencia de RD cuando los ojos están sanos. Del mismo modo, en la segunda prueba se presenta un patrón similar, clasificándose tres imágenes con RD y cinco imágenes con presencia de la enfermedad, aun cuando las personas no la padecen.

Estos resultados se contrastan con los obtenidos por trabajos que implementan SVM en problemas relacionados. Por

Tabla II. Pruebas de eficiencia del clasificador. Resultados del clasificador empleando el kernel = 'rbf'

Pruebas	Entrenamiento	Prueba	Matriz de confusión	
40 imágenes	80 %	20 %	TP 2	TP 0
20 con RD, 20 sin RD	32 imágenes	8 imágenes	FN 6	FN 0
30 imágenes	75 %	25 %	TP 3	TP 0
15 con RD, 15 sin RD	18 imágenes	6 imágenes	FN 5	FN 0

ejemplo, Raj S *et al.* (2023) documenta las pruebas de una SVM para los diferentes tipos de kernel, alcanzando una precisión del 84% promedio. Del mismo modo, Al-hazaimah *et al.* (2022) muestra resultados eficientes en el desempeño de una SVM, alcanzando una precisión del 98.71% con una implementación simple y del 99.2% con una implementación híbrida (SVMGA). Sin embargo, en estos trabajos no se documenta la configuración de los parámetros empleados en las pruebas, por lo que sugiere que una variación de estos o una combinación de la SVM con otras técnicas podría encaminar las pruebas hacia un mejor desempeño del clasificador.

Discusión

El porcentaje del 54% obtenido en el análisis predictivo del algoritmo de clasificación debe interpretarse como un indicador de bajo desempeño del modelo en la tarea de detección temprana de retinopatía diabética (RD). Dado que el contexto aborda un escenario de clasificación binaria (con RD y sin RD), este porcentaje sugiere que el modelo apenas supera la barrera de un escenario de aleatoriedad, lo cual representa un nivel de confianza insuficiente para poder emplear la herramienta en escenarios clínicos realistas, ya que puede comprometer la seguridad del paciente en caso de que se utilice sin una mejora sustancial.

No obstante, este resultado también revela un área de oportunidad para el perfeccionamiento de la herramienta, lo cual es visible si se considera también a aquellos factores externos que pueden incidir en la eficiencia del clasificador, entre los que se encuentran: la calidad y la dimensión de las imágenes (variantes en una gran cantidad de imágenes del repositorio de prueba), las condiciones no controladas de iluminación durante la captura (que generan zonas oscuras e ilegibles en las imágenes), las deficiencias en la calibración de los dispositivos de adquisición, así como errores en la configuración de los programas de procesamiento y almacenamiento. Estos elementos afectan negativamente la calidad del conjunto de datos y pueden introducir sesgos en el entrenamiento y la validación del modelo.

En consecuencia, la precisión reportada obedece también a una manifestación cuantitativa de las limitaciones inherentes al conjunto de datos y al entorno de recolección. Lo anterior plantea la necesidad de implementar estrategias de mejora, tanto en la fase de adquisición de imágenes (empleando protocolos estandarizados), o bien, en el diseño del modelo mediante el uso de técnicas alternativas de preprocesamiento, el incremento en los datos requeridos para el entrenamiento del clasificador, o mediante el empleo de arquitecturas más

sofisticadas como las redes neuronales artificiales o los métodos de aprendizaje profundo (*deep learning*).

Conclusiones

El presente trabajo presentó una aproximación inicial para la construcción de un método robusto que permita el diagnóstico de RD mediante el uso de imágenes de fondo de ojo, en términos de la extracción de las características del padecimiento y el análisis predictivo para proveer un diagnóstico que permita producir un método de análisis automático de las imágenes y efectuar una clasificación.

En esta aproximación inicial, se observó que la técnica de diagnóstico permite obtener un antecedente de la manifestación del padecimiento, el cual, una vez que se perfeccione será una herramienta útil, sobre todo en casos en donde no se cuenta con especialistas que puedan brindar la atención y el seguimiento del padecimiento en el corto plazo a causa de las limitantes existentes en la distribución de los especialistas en México. En vías de mejorar la precisión alcanzada, se recomienda explorar métodos alternativos de diagnóstico que puedan ser soportados por mejoras documentadas de la SVM presentada, o bien, mediante otros algoritmos de machine learning, los cuales faciliten la labor de los médicos y sienten las bases para producir una solución tecnológica con una alta confiabilidad que permita diagnosticar y atender oportunamente el padecimiento por parte del área de oftalmología.

Agradecimientos

Agradecemos las observaciones y

recomendaciones realizadas por los revisores para mejorar el contenido del presente documento.

Referencias

- Al-Hazaimh, O., A. Abu-Ein, N. Tahat, M. Al-Smadi & M. Al-Nawashi. 2022.** Combining Artificial Intelligence and Image Processing for Diagnosing Diabetic Retinopathy in Retinal Fundus Images. *International Journal of Online and Biomedical Engineering* 18 (13): 131-151.
- Data Science Team. 2020.** Capítulo 2: SVM (Support Vector Machine) – Teoría. Consultado el 15 de enero de 2025: <https://datascience.eu/es/matematica-y-estadistica/capitulo-2-svm-support-vector-machine-teoria/>.
- Heidari, S., T. Babor, P. De Castro, S. Tort & M. Curno. 2018.** Equidad según sexo y de género en la investigación: justificación de las guías SAGER y recomendaciones para su uso. *Gaceta sanitaria* 33 (2): 203-210.
- IMSS. 2023.** Protocolo de atención integral. Retinopatía diabética. Consultado el 10 de febrero de 2025. Disponible en: <https://www.imss.gob.mx/sites/all/statics/profesionalesSalud/investigacionSalud/historico/programas/16-pai-retinopatia-diabetica.pdf>
- INEGI. 2021a.** Estadísticas a propósito del día mundial de la diabetes. Consultado el 2 de febrero de 2025. Disponible en: https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2021/EAP_Diabetes2021.pdf.
- INEGI. 2021b.** Estadísticas a propósito de las personas ocupadas como médicos. Consultado el 4 de febrero de 2025. Disponible en: https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2021/EAP_Medico2021.docx.
- Kaggle Aptos. 2019.** Aptos - 2019 Blindness Detection. Consultado el 22 de enero de 2025. Disponible en: <https://www.kaggle.com/datasets/mariaherrerot/aptos2019>.
- Malhi, A. 2023.** Detección y clasificación de la retinopatía diabética mediante imágenes digitales de la retina. *Revista internacional de aplicaciones y robótica inteligente*: 1-34.
- Oh, K., H. Min-Kang, D. Leem, H. Lee, K. Yul-Seo & S. Yoon. 2021.** Early detection of diabetic retinopathy based on deep learning and ultra-wide-field fundus images. *Scientific reports* 11: 1-9.

- Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos & D. Cournapeau. 2011.** Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research* 12: 2825-2830.
- Raj S, B., L. Gibson, G. Chinnadurai, J. Vijay, V. Janakiraman & P. Anand. 2023.** Support vector machine for image classification. *Journal of the Asiatic Society of Mumbai* 97 (4): 1-10.
- Resnikoff, S., V. Lansigh, L. Washburn, W. Felch, T. Gauthier, H. Taylor, K. Eckert, D. Parke & P. Wiedemann. 2020.** Estimated number of ophthalmologists worldwide (International Council of Ophthalmology update): will we meet the needs?. *Br J Ophthalmol* 104 (4): 588-592.
- Sandoval, J. L. 2020.** Proyección en el sector salud 2018-2024, análisis y consecuencias. *Revista médica del Instituto Mexicano del Seguro Social* 58 (2): 80-83.
- Stella Mary, M. C. V., E. B. Rajsingh & G. R. Naik. 2016.** Retinal Fundus Image Analysis for Diagnosis of Glaucoma: A Comprehensive Survey. *IEEE* 4: 4327-4354. DOI: 10.1109/ACCESS.2016.2596761.
- Sahlsten, J., J. Jaskari, J. Kivinen, L. Turunen, E. Jaanio, K. Hietala & K. Kaski. 2019.** Deep Learning Fundus Image Analysis for Diabetic Retinopathy and Macular Edema Grading. *Scientific reports* 9: 1-11.
- Uppamma, P., S. Bhattacharya & O. Geman. 2023.** Deep Learning and Medical Image Processing Techniques for Diabetic Retinopathy: A survey of Applications, Challenges and Future Trends. *Journal of Healthcare Engineering* 1-18.
- Wisaeng, K., N. Hiransakolwong, & E. Pothiruk. 2012.** Automatic Detection of Exudates in Diabetic Retinopathy Images. *Journal of Computer Science* 8 (8): 1304-1313.