

# Clasificación binaria y multiclase de Retinopatía Diabética con características profundas de imágenes mejoradas en LAB y YCbCr

Ángel Salazar Alvarez<sup>1</sup>, Pedro Arguijo<sup>1,2,\*</sup>,  
José Antonio Hiram Vázquez López<sup>2</sup>, David Lara Alabazares<sup>1</sup>

<sup>1</sup> Tecnológico Nacional de México,  
Instituto Tecnológico Superior de Misantla,  
División de Estudios de Posgrado e Investigación,  
México

<sup>2</sup> Tecnológico Nacional de México,  
Instituto Tecnológico Superior de Misantla,  
División de Ingeniería en Sistemas Computacionales,  
México

222T0541@itsm.edu.mx, pedroarguijo16@gmail.com

**Resumen.** La Retinopatía Diabética (DR) es una complicación de la diabetes que afecta gradualmente la visión, su identificación y grado de severidad permite tomar medidas preventivas y correctivas. Se realizó la clasificación binaria y multiclase de características profundas extraídas con DenseNet-121 y Ademxapp Model A tanto en las imágenes sin procesar como de imágenes mejoradas en los espacios de color LAB y YCbCr. En la clasificación binaria se determina la presencia o ausencia de DR y en la multiclase el grado de severidad. La clasificación se realizó con Support Vector Machine (SVM), Random Forest (RF) y Gradient-Boosted Trees (GBT). Para la clasificación binaria se obtuvieron resultados de exactitud del 98% mientras que para la multiclase del 84%.

**Palabras clave:** Retinopatía diabética, características profundas, SVM, RF, GBT, DenseNet 121, ademxapp model A, LAB, YCbCr.

## Binary and Multiclass Classification of Diabetic Retinopathy with Deep Features of Enhanced Images in LAB and YCbCr

**Abstract.** Diabetic Retinopathy (DR) is a complication of diabetes that gradually affects vision, its identification and degree of severity allows preventive and corrective measures to be taken. Binary and multiclass classification of deep features extracted with DenseNet-121 and Ademxapp Model A was performed on both raw and enhanced images in LAB and YCbCr color spaces. Binary classification determines the presence or absence of DR and multiclass classification determines the degree of severity. Classification was performed with Support Vector Machine (SVM), Random Forest (RF) and Gradient-

Boosted Trees (GBT). For the binary classification, 98% accuracy results were obtained, while for the multiclass classification, 84% accuracy was obtained.

**Keywords:** Diabetic retinopathy, deep features, SVM, RF, GBT, DenseNet 121, Ademxapp Model A, LAB, YCbCr.

## 1. Introducción

La diabetes o diabetes mellitus, es una enfermedad crónica que altera el metabolismo de la glucosa en la sangre, siendo la diabetes tipo 1 y tipo 2 las más comunes. Mientras que en la primera, el cuerpo no produce suficiente insulina; como consecuencia de la destrucción de células pancreáticas, en la de tipo 2, el cuerpo se vuelve resistente a la insulina; lo que puede provocar hiperglucemia, es decir, un aumento de azúcar en la sangre. La falta de control de este padecimiento puede acarrear serias y diversas complicaciones de salud, tales como enfermedades cardíacas, daño renal, problemas de la visión y neuropatías [1].

Globalmente, 1 de cada 10 adultos de 20 a 79 años padecen algún tipo de diabetes, además, cada vez hay más países en los que 1 de cada 5, incluso más, se encuentran con la misma situación. La Federación Internacional de Diabetes (IDF, por sus siglas en inglés) reportó que en el año 2021 había 537 millones de personas con diabetes. Además, estimó que habrá 643 y 783 millones de personas con este padecimiento hacia los años 2030 y 2045, respectivamente. Así mismo, la IDF señala que la región de Canadá, México, Estados Unidos y algunos países del Caribe presentan la segunda mayor mortalidad por diabetes y el segundo porcentaje más alto de muertes de personas en edad laboral, de igual manera es la región que tiene el mayor gasto relacionado con esta enfermedad [2]. En México, la diabetes se posicionó como la segunda causa de defunciones [3], de ahí la importancia de la concientización, diagnóstico oportuno y control adecuado de esta condición.

Como se mencionó, la diabetes puede acarrear diversas complicaciones médicas en aquellas personas diagnosticadas con este padecimiento. Estas se dividen en microvasculares y macrovasculares en relación con el tamaño de los vasos sanguíneos afectados en el cuerpo. Entre las complicaciones microvasculares se incluyen la nefropatía, la neuropatía y la retinopatía; entre las complicaciones macrovasculares se encuentran las enfermedades cardiovasculares y de arteria periférica, por mencionar algunas [4].

La Retinopatía Diabética (DR por sus siglas en inglés), es una complicación ocular de la diabetes que afecta a los vasos sanguíneos de la retina debido a altos niveles de glucosa en la sangre, lo que provoca que estos se inflamen y en ocasiones se obstruyan o incluso se presenten hemorragias. En etapas prematuras puede ocasionar visión borrosa o pérdida parcial hasta llegar a los estados más avanzados donde puede ocurrir la pérdida total de la visión. Por lo tanto, es importante que las personas diagnosticadas con diabetes se sometan a estudios oftalmológicos periódicos para detectar DR en etapas tempranas, controlar su progreso y evitar el riesgo de ceguera. La DR puede ser no proliferativa (NPDR) y proliferativa (PDR), en la primera aparecen lesiones tempranas progresivas, mientras que la segunda se refiere a un escenario más avanzado y serio de la enfermedad. Estudios realizados muestran que el 34% de la población diagnosticada con diabetes presenta alguno de estos niveles de DR [5].

La detección manual de la DR presenta desafíos considerables, es un proceso que demanda un tiempo considerable, además de ser susceptible a errores de diagnóstico y




Fig. 1. Tipos de lesiones de DR [5].

Tabla 1. Clasificación de DR.

Grado de Retinopatía Diabética	Lesiones
No DR	No hay lesiones.
DR leve	Solo MA.
DR moderada	Más que MA, pero menos que DR grave.
DR grave	Cualquiera de las siguientes: <ul style="list-style-type: none"> <li>- Mas de 20 HM intrarretinales cada 4 cuadrantes.</li> <li>- Vasos sanguíneos bien definidos en más de 2 cuadrantes.</li> <li>- Anormalidades microvasculares intrarretinales en al menos 2 cuadrantes sin señales de DR proliferativa.</li> </ul>
DR proliferativa	Una o más de las siguientes: <ul style="list-style-type: none"> <li>- Neovascularización.</li> <li>- HM pre-retinales.</li> </ul>

puede resultar costoso. El diagnóstico se realiza mediante la observación a través de lentes especiales y la utilización de equipo especializado para escanear la retina y proveer imágenes detalladas que ayudan al especialista en el análisis, búsqueda y medición de las lesiones oculares (ver Fig. 1), lesiones rojas conocidas como microaneurismas (MA) y hemorragias (HM), lesiones brillantes conocidas como exudados blandos y duros (EX), además es posible observar el crecimiento anormal de nuevos vasos sanguíneos denominado como neovascularización [6].

En la Tabla 1, se muestran las etapas de la DR que depende del tipo y número de lesiones en la retina [7].

El desarrollo e implementación de sistemas de diagnóstico asistido por computadora (CAD, por sus siglas en inglés) surge como una alternativa prometedora para superar

las limitaciones mencionadas en la detección manual de la DR. En la última década, los CAD basados en aprendizaje profundo (DL, por sus siglas en inglés) han demostrado un gran potencial para la detección precisa y eficiente de la DR. El DL se caracteriza por su capacidad para aprender directamente de grandes conjuntos de datos, sin necesidad de una extracción manual de características. Esta propiedad lo convierte en una herramienta ideal para el análisis de imágenes médicas, donde la identificación de patrones complejos es crucial. En contraste, los métodos de aprendizaje automático (ML, por sus siglas en inglés) sí requieren la extracción previa de características, pero necesitan menos datos para su entrenamiento.

En este trabajo realizamos una comparación en la clasificación binaria y multiclase del grado de DR considerando características profundas extraídas con arquitecturas previamente entrenadas. En la clasificación binaria se determina la presencia o ausencia de DR en las imágenes, mientras que en la clasificación multiclase, se especifica el grado de DR presente en las imágenes. Las imágenes se mejoraron con dos técnicas, reportadas en la literatura, las cuales incrementan los detalles significativos de las imágenes. Como extractores de características profundas empleamos Adexapp Model A y DenseNet 121. La clasificación de las características profundas se realizó con Support Vector Machine (SVM), Random Forest (RF) y Gradient-Boosted Trees (GBT).

El resto del manuscrito se organiza como se menciona a continuación. En la siguiente sección se abordan trabajos relacionados con la detección de DR a través de características profundas. Los clasificadores utilizados y los extractores de características profundas se describen en la sección 3. En la sección 4 se aborda la metodología empleada junto con las métricas consideradas. Los resultados se muestran y discuten en la sección 5. Finalmente, en la sección 6 se presentan las conclusiones del desarrollo de la investigación.

## 2. Trabajos relacionados

Para la predicción del grado de DR a partir de imágenes, se han propuesto una amplia gama de algoritmos y técnicas. Entre las más destacadas se encuentran las redes neuronales convolucionales (CNN, por sus siglas en inglés), las cuales han demostrado un alto rendimiento tanto en la detección binaria de DR como en la identificación de la severidad de la enfermedad mediante clasificación multiclase; en diferentes dataset de imágenes, entre los que se encuentran APTOS 2019, MESSIDOR e IDRID, por mencionar algunos; una descripción de estos dataset y otros más se encuentra en [8].

Kassani y colaboradores propusieron una arquitectura modifica de Xception concatenando características de las capas intermedias y compararon su eficiencia contra las arquitecturas entrenadas InceptionV3, MobileNet y ResNet50; obteniendo una exactitud del 83% para la para la clasificación del dataset ICDRSS [9]. Bodapati y colaboradores proponen una red neuronal profunda con un mecanismo de atención entrenada con características de diversas CNN preentrenadas, además utilizan métodos de reducción espacial para lograr representaciones condensas de la información al clasificar obteniendo una exactitud de 82.54% en el dataset APTOS 2019 [10]. Mobeen-ur-Rehman y Khan, utilizaron CNNs preentrenadas, VGG-16, AlexNet y SqueezeNet, además de una red neuronal propia de 5 capas, 2 capas de convolución y 3 completamente conectadas, para la identificación de la presencia de DR en imágenes de retina, obteniendo exactitudes del 98% en cada escenario [11]. Wejdan y Maysoun proponen dos de aprendizaje profundo, CNN512 para la clasificación de imágenes de

DR en sus 5 etapas, y YOLOv3 para la detección y localización de las lesiones. La combinación de ambos modelos resulta en un sistema integral de clasificación y localización de las lesiones de DR con una exactitud de 89% [12].

Bilal y Sun proponen un enfoque diferente a CNNs, un enfoque híbrido para detectar las lesiones de la retina y su clasificación para identificar la etapa de la enfermedad, someten las imágenes a un preprocesamiento aprovechando el espacio de color YCbCr para mejorar la calidad de las muestras y realizar la detección de las lesiones además de extraer sus características, emplean SVM, k-vecinos más cercanos (KNN) y árboles de decisión para llevar a cabo la clasificación, finalmente someten a votación el resultado de los clasificadores obteniendo una exactitud de 98.06% [13]. Makmur y Kwan aplican y comparan dos técnicas de extracción de características de imágenes, Patrones Locales Binarios (LBP) y Matriz de Concurrencia de Niveles de Gris (GLCM), para mejorar el diagnóstico del grado de DR. Comparan el rendimiento de ambas técnicas utilizando SVM, bosque aleatorio y regresión logística y evalúan exactitud de la clasificación de DR obteniendo exactitudes entre el 73% y 74% [14].

### **3. Marco teórico**

#### **3.1. Support Vector Machine**

Support Vector Machine son un algoritmo propuesto en los años 90 [15] para resolver problemáticas de clasificación binaria, actualmente se utiliza ampliamente para problemas de regresión y clasificación multiclase en diversas áreas, tales como visión, artificial, reconocimiento de objetos, procesamiento de lenguaje natural, entre otras [16]. La idea principal de SVM es encontrar el separador lineal, denominado como hiperplanos, que separe las diferentes clases del conjunto de datos sobre el espacio de características. Los puntos que se encuentran más cerca del hiperplano se denominan vectores de soporte.

#### **3.2. Random Forest**

Random Forest es un algoritmo de aprendizaje automático, introducido por Leo Breiman [17], utilizado principalmente para tareas de clasificación y regresión. Es un método de aprendizaje no paramétrico por conjuntos basado en árboles de decisión, combina la idea de los vecinos más cercanos adaptativos con el bagging [18]. Es un grupo de árboles de clasificación o regresión, de acuerdo a su función, que se forman a partir de la selección aleatoria de los datos del conjunto de datos de entrenamiento y cuando se trata de realizar predicciones con nuevos datos, cada árbol en el bosque emite una predicción y la clase o valor más común entre los árboles se elige como la predicción final, es decir, la predicción final depende del voto mayoritario en cuanto a clasificación o el promedio cuando su función es regresión [19].

#### **3.3. Gradient Boosted Trees**

Los árboles impulsados por gradiente son una técnica de aprendizaje automático utilizada para problemas de regresión y clasificación, combina múltiples modelos más simples, normalmente árboles de decisión, para mejorar la precisión y la generalización del modelo final [20]. La idea principal de este algoritmo es entrenar árboles de decisión secuencialmente, de tal forma que cada nuevo árbol se enfoca en corregir los

errores del modelo anterior, las funciones de pérdida aplicadas pueden ser arbitrarias y depende del investigador o la tarea específica en cada situación [21].

### 3.4. Ademxapp Model A

Es una CNN presentada por investigadores de la Universidad de Adelaida en 2016, una arquitectura de redes residuales, menos profunda, que supera el rendimiento de modelos más profundos como ResNet-200 en el conjunto de entrenamiento de ImageNet [22].

Crearon 6 modelos, A, B, C, D, E y F de esta arquitectura, con diferentes tamaños de entrada, diferentes kernels y los evaluaron con el dataset de clasificación ImageNet Large Scale Visual Recognition Challenge (ILSVR) 2012 frente a otras arquitecturas, VGG16, ResNet-50, ResNet101, ResNet1-52, ResNet200, Inception demostrando mayor eficiencia desde el punto de vista espacial y mejor rendimiento no solo en clasificación del conjunto de datos sino también en la segmentación de las imágenes. ILSVR es un conjunto de imágenes que consta de 1.2 millones de imágenes de entrenamiento con 1000 clases de objetos.

### 3.5. DenseNet-121


La arquitectura DenseNet ha sido utilizada en diversas áreas debido a su gran rendimiento, se ha empleado para el diagnóstico de varias enfermedades por ejemplo para la detección de Alzheimer, COVID-19, enfermedades de plantas, incluso condiciones climáticas. DenseNet proporciona arquitecturas con diferentes profundidades que pueden mejorar los resultados de los modelos de aprendizaje profundo [23].

Estas redes convolucionales profundas, conectan cada capa con todas las demás de forma feed-forward, donde cada capa utiliza como entrada los mapas de características de todas las capas anteriores, y sus propios mapas de características se utilizan como entrada en todas las capas posteriores [24].


DenseNet-121 logró una exactitud de 75% en el conjunto de validación original de ILSVR 2012.

## 4. Metodología


El conjunto de imágenes en este trabajo es APTOS 2019 Blindness Detection [25]. Imágenes representativas del fondo del ojo en el que se indica el grado de DR, o sea, No DR, leve, moderada, grave y DR proliferativa, se muestran en la figura 2. Similar a otros datasets de acceso público, algunas imágenes presentan diversos problemas como: bajo contraste, desenfoque, imágenes con diferente resolución espacial que van desde los 474×358 píxeles hasta 4288×2848 píxeles, entre otras. Es importante destacar que es un conjunto de imágenes desbalanceado, es decir, que las diferentes clases o muestras respectivas a cada grado de DR cuentan con cantidades diferentes de imágenes, que afectan directamente el desempeño de los modelos de clasificación, cuenta con 1805 muestras de clase No DR, 370 de clase leve, 999 de clase moderada, 193 de clase grave y 295 de clase DR proliferativa.



**Fig. 2.** Etapas DR Aptos 2019 en espacio de color RGB. Muestra representativa de cada grado de retinopatía proporcionado en el conjunto de datos [25].



**Fig. 3.** Etapas DR Aptos 2019 mejoradas en espacio de color LAB.



**Fig. 4** Etapas DR Aptos 2019 mejoradas en espacio de color YCbCr.

Con la finalidad de resaltar detalles significativos de las imágenes se mejoraron en los espacios de color LAB [26] y YCbCr [6]. Las imágenes mejoradas en LAB y YCbCr se muestran en las figuras 3 y 4, respectivamente.

Los vectores de características correspondientes a cada arquitectura se obtuvieron a partir de las capas de agregación de ambas redes, DenseNet-121 genera un vector de 1024 características profundas mientras que Ademxapp Model A genera un vector de 4096 características.

Los vectores característicos correspondientes a cada espacio de color se clasificaron en dos escenarios, el primero para evaluar la presencia o ausencia de DR y el segundo para identificar el grado de DR.

Para realizar la clasificación binaria se unieron las muestras de las clases leve, moderada, severa y proliferativa como la presencia de DR y NoDR para representar la ausencia de la enfermedad. En el caso de clasificación multiclase, se consideraron las etiquetas proporcionadas por el autor del dataset.

El desempeño de los modelos entrenados se evalúa con métricas que se obtienen de su respectiva matriz de confusión. Las métricas proporcionan información valiosa sobre el rendimiento de los modelos de aprendizaje automático al momento de realizar predicciones, existen diversas métricas y cada una aborda diferentes aspectos y contextos cuando se pretende evaluar el desempeño. Para conocer el rendimiento de los modelos obtenidos durante este estudio se consideraron tres métricas, exactitud, recall y F1 score:

$$\text{Exactitud} = \frac{TP+TN}{TP+FP+TN+FN}. \quad (1)$$

La exactitud proporciona una medida global de las predicciones correctas que realiza un modelo entre el número total de predicciones, pero cuando las clases no están completamente balanceadas conviene emplear otras métricas de evaluación que consideren la distribución entre las clases:

$$\text{Recall} = \frac{TP}{P} = \frac{TP}{TP+FN}. \quad (2)$$

Recall mide la capacidad de un modelo para predecir correctamente los ejemplos positivos entre el total de los ejemplos positivos. Proporciona una medida específica a cada una de las clases evaluadas, para realizar una medida global del rendimiento del modelo es necesario considerar un promedio ponderado de cada clase, ecuación 3:

$$\text{Recall}_{\text{GLOBAL}} = \frac{\sum_{i=1}^n \text{Recall}_i \cdot m_i}{\sum_{i=1}^n m_i}, \quad (3)$$

donde  $i$  se refiere a la clase,  $n$  es el número de clases y  $m$  indica las muestras por clase:

$$\text{F1 Score} = \frac{2TP}{2TP+FP+FN}. \quad (4)$$

F1 Score combina la precisión y recall una clase para obtener un valor más objetivo, similar a recall, es una medida específica de cada clase, para obtener un F1 Score global se consideró el promedio ponderado, ecuación 5:

$$\text{FS}_{\text{GLOBAL}} = \frac{\sum_{i=1}^n \text{F1 Score}_i \cdot m_i}{\sum_{i=1}^n m_i}, \quad (5)$$

donde *F1 Score* se refiere al F1 Score individual de una clase,  $n$  es el número de clases y  $m$  indica las muestras por clase.

## 5. Resultados

Se clasificaron los vectores de características profundas de las imágenes originales, o sea sin procesar, y de las imágenes mejoradas en los espacios de color LAB y YCbCr con RF, SVM y GBT.

### 5.1. Clasificación binaria

En las tablas 2, 3 y 4 se muestran los resultados de la clasificación binaria, o sea, la presencia o ausencia de DR tanto en las imágenes originales y en las mejoradas. Como se puede observar en las imágenes procesadas en los espacios de color LAB y YCbCr se obtienen desempeños similares en las métricas consideradas en comparación con las imágenes originales. Con los vectores de características extraídas en las imágenes procesadas en el espacio de color LAB se obtienen los mejores resultados sin importar el extractor de características profundas.



**Tabla 2.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes originales.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.9631	0.9631	0.9631	0.9645	0.9645	0.9645
<b>SVM</b>	0.9781	0.9781	0.9781	0.9740	0.9740	0.9740
<b>GBT</b>	0.9727	0.9727	0.9727	0.9672	0.9672	0.9672

**Tabla 3.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes mejoradas en el espacio de color LAB.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.9577	0.9577	0.9577	0.9713	0.9713	0.9713
<b>SVM</b>	0.9809	0.9809	0.9809	0.9713	0.9713	0.9713
<b>GBT</b>	0.9645	0.9645	0.9645	0.9618	0.9618	0.9618

**Tabla 4.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes mejoradas en el espacio de color YCbCr.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.9658	0.9658	0.9658	0.9672	0.9672	0.9672
<b>SVM</b>	0.9768	0.9768	0.9768	0.9754	0.9754	0.9754
<b>GBT</b>	0.9699	0.9699	0.9699	0.9658	0.9658	0.9658

SVM es el algoritmo que obtiene mejores resultados para este tipo de clasificación en cualquiera de los espacios de color propuestos a través de las características extraídas por medio de Ademxapp Model A y DenseNet-121 demuestra un desempeño consistente en cualquiera de los tres algoritmos de clasificación.

Analizando las métricas obtenidas, demostramos que SVM logra una exactitud de 98% en clasificación binaria con Ademxapp Model A como extractor de características con las imágenes mejoradas a través del espacio de color LAB y 97% de exactitud en cualesquiera de los demás escenarios propuestos, ya sea en diferente espacio de color o extractor de características.

## 5.2. Clasificación multiclase

Para la clasificación multiclase, de acuerdo con los resultados mostrados en las tablas 5, 6 y 7, no se demuestra una diferencia significativa en relación con las técnicas de mejoramiento de imágenes planteadas en los espacios de color RGB y LAB, ambas técnicas muestran en general un desempeño similar respecto a la identificación de los grados de DR a través de las arquitecturas de extracción utilizadas. Se observa nuevamente que SVM ofrece el mejor modelo de clasificación siendo estos resultados similares a los reportados en [10].

Por otro lado, Ademxapp Model A proporciona 91% cuando se trata de identificar los casos positivos mediante SVM, sin embargo, RGB es más consistente en recall cuando mediante GBT y SVM.

**Tabla 5.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes originales.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.7653	0.7163	0.8880	0.7967	0.7698	0.8857
<b>SVM</b>	0.8267	0.8146	0.9071	0.8226	0.8144	0.9023
<b>GBT</b>	0.7994	0.7753	0.9000	0.8158	0.8043	0.9047

**Tabla 6.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes mejoradas en el espacio de color LAB.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.7735	0.7349	0.8880	0.7858	0.7549	0.8952
<b>SVM</b>	0.8431	0.8327	0.9128	0.8130	0.8015	0.8928
<b>GBT</b>	0.7912	0.7709	0.8952	0.8076	0.7932	0.8833

**Tabla 7.** Resultados obtenidos en la clasificación binaria en el conjunto de imágenes mejoradas en el espacio de color YCbCr.

	Ademxapp Model A			DenseNet 121		
	ACC	FS	Re	ACC	FS	Re
<b>RF</b>	0.7503	0.7047	0.8666	0.7721	0.7352	0.8809
<b>SVM</b>	0.8349	0.8232	0.9095	0.8076	0.7916	0.8833
<b>GBT</b>	0.7748	0.7442	0.8690	0.8062	0.7900	0.8904

## 6. Conclusiones

El diagnóstico del grado de DR es una tarea compleja debido a diversas problemáticas que enfrentan los conjuntos de datos o imágenes a utilizar para su diagnóstico, es necesario desarrollar técnicas eficientes para minimizar los efectos negativos y mejorar el desempeño y por ende los resultados de los modelos de clasificación.

Cuando se trata de identificar la presencia o ausencia de DR en el dataset propuesto, se logran resultados sobresalientes con cada uno los escenarios planteados, SVM demostró ser el mejor modelo de clasificación a través de los vectores generados por Ademxapp Model A a partir de las imágenes mejoradas en el espacio de color LAB con 98% de exactitud frente a los 97% de exactitud de DenseNet-121, siendo RF el clasificador con el desempeño más bajo obteniendo tan solo el 95% de exactitud, pero considerando el costo computacional que conlleva la extracción de las características de Ademxapp Model A y entrenamiento de SVM, DenseNet-121 puede proporcionar una mejora considerable en cuanto al tiempo en general y exactitud.

La identificación de la etapa de DR en la que se encuentran las muestras es más compleja, si bien SVM y Ademxapp Model A proporcionan las métricas más sobresalientes cuando se utiliza el espacio de color LAB, trabajar en el espacio de color RGB a través de la arquitectura DenseNet puede ofrecer prácticamente los mismos resultados con un costo computacional menor, puesto que no requiere mejorar las imágenes y la extracción de características requiere una cantidad de tiempo considerablemente menor.

Es necesario continuar experimentando con más arquitecturas, desarrollar o aplicar otras técnicas de mejoramiento de imágenes para incrementar los resultados de clasificación, así como para discriminar las muestras que no aportan información útil al momento de definir correctamente cualquiera de las clases de DR.

## Referencias

1. American Academy of Ophthalmology: <https://www.aao.org> (2024)
2. International Diabetes Federation: <https://idf.org> (2024)
3. INEGI, <https://www.inegi.org.mx> (2024)
4. Papatheodorou, K., Banach, M., Bekiari, E., Rizzo, M., Edmonds, M.: Complications of Diabetes 2017. *Journal of Diabetes Research* (2018). DOI: 10.1155/2018/3086167.
5. Fung, T.H., Patel, B., Wilmot, E.G., Amoaku, W.M.: Diabetic Retinopathy for the Non-Ophthalmologist. *Clinical Medicine*, vol. 22, no. 2, pp. 112–116 (2022). DOI: 10.7861/clinmed.2021-0792.
6. Bilal, A., Sun, G., Li, Y., Mazhar, S., Khan, A.Q.: Diabetic Retinopathy Detection and Classification using Mixed Models for a Disease Grading Database. *IEEE Access*, vol. 9, pp. 23544–23553 (2021). DOI: 10.1109/ACCESS.2021.3056186.
7. Wilkinson, C.P., Ferris III, F.L., Klein, R.E., Lee, P.P., Agardh, C.D., Davis, M.: Global Diabetic Retinopathy Project Group. Proposed International Clinical Diabetic Retinopathy and Diabetic Macular Edema Disease Severity Scales. *Ophthalmology*, vol. 110, no. 9, pp. 1677–1682 (2003). DOI: 10.1016/S0161-6420(03)00475-5.
8. Nagpal, D., Panda, S.N., Malarvel, M., Pattanaik, P.A., Khan, M.Z.: A Review of Diabetic Retinopathy: Datasets, Approaches, Evaluation Metrics and Future Trends. *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 9, pp. 7138–7152. DOI: 10.1016/j.jksuci.2021.06.006.
9. Kassani, S.H., Kassani, P.H., Khazaeinezhad, R., Wesolowski, M.J., Schneider, K.A., Deters, R.: Diabetic Retinopathy Classification Using a Modified Xception Architecture. In: *IEEE International Symposium on Signal Processing and Information Technology*, pp. 1–6 (2019). DOI: 10.1109/ISSPIT47144.2019.9001846.
10. Bodapati, J.D., Shaik, N., Naralasetti, V.: Composite Deep Neural Network with Gated-Attention Mechanism for Diabetic Retinopathy Severity Classification. *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, pp. 1–15 (2021). DOI: 10.1007/s12652-020-02727-z.
11. Mobeen-Ur-Rehman, Sharzil Haris Khan, Zeeshan Abbas, Danish Rivzi, S.M.: Classification of Diabetic Retinopathy Images based on Customised CNN Architecture. In: *Amity International Conference on Artificial Intelligence, AICAI'19*, Institute of Electrical and Electronics Engineers Inc., pp. 244–248 (2019). DOI: 10.1109/AICAI.2019.8701231.
12. Alyoubi, W.-L., Abulkhair, M.F., Shalash, W.M.: Diabetic Retinopathy Fundus Image Classification and Lesions Localization System Using Deep Learning. *Sensors*, vol. 21, no. 11, pp. 3704 (2021). DOI: 10.3390/s21113704.
13. Bilal, A., Sun, G., Li, Y., Mazhar, S., Khan, A.Q.: Diabetic Retinopathy Detection and Classification using Mixed Models for a Disease Grading Database. *IEEE Access*, vol. 9, pp. 23544–23553 (2021). DOI: 10.1109/ACCESS.2021.3056186.
14. Makmur, N.M., Kwan, F., Rana, A.D., Kurniadi, F.I.: Comparing Local Binary Pattern and Gray Level Co-occurrence Matrix for Feature Extraction in Diabetic Retinopathy Classification. *Procedia Computer Science*, vol. 227, pp. 355–363 (2023). DOI: 10.1016/j.procs.2023.10.534.
15. Cortes, C., Vapnik, V.: Support-Vector Networks. *Mach Learn*, vol. 20, pp. 273–297 (1995). DOI: 10.1007/BF00994018.
16. Carmona, E.: Tutorial sobre Máquinas de Vectores Soporte (2016)

17. Breiman, L.: Random Forests. *Machine Learning*, vol. 45, pp. 5–32 (2001)
18. Breiman, L.: Bagging predictors. *Mach Learn*, vol. 24, pp. 123–140 (1996). DOI: 10.1007/BF00058655.
19. Ali, J., Khan, R., Ahmad, N., Maqsood, I.: Random Forests and Decision Trees. In: *International Journal of Computer Science Issues (IJCSI)*, vol. 9, no. 5, pp. 272 (2012)
20. Fafalios, S., Charonyktakis, P., Tsamardinos, I.: Gradient Boosting Trees. *Gnosis Data Analysis PC*, pp. 1–3 (2020)
21. Natekin, A., Knoll, A.: Gradient Boosting Machines, a Tutorial. *Frontiers in Neurorobotics*, vol. 7, no. 21 (2013)
22. Wu, Z., Shen, C., Hengel, A.: Wider or Deeper: Revisiting the ResNet Model for Visual Recognition. *Pattern Recognition*, vol. 90, pp. 119–133 (2016). DOI: 10.1016/j.patcog.2019.01.006.
23. Albelwi, S.: Deep Architecture based on DenseNet-121 Model for Weather Image Recognition. In: *International Journal of Advanced Computer Science and Applications*, vol. 13 (2022). DOI: 10.14569/IJACSA.2022.0131065.
24. Huang, G., Liu, Z., Van Der-Maaten, L., Weinberger, K.Q.: Densely Convolutional Networks. In: *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4700–4708 (2017). DOI: 10.1109/CVPR.2017.243.
25. Karthik, M., Sohler, D.: APTOS 2019 Blindness Detection. *Kaggle* (2019) <https://kaggle.com/competitions/aptos2019-blindness-detection>.
26. Priyadharsini, C., Jagadeesh-Kannan, R.: Retinal Image Enhancement based on Color Dominance of Image. *Scientific Reports*, vol. 13, pp. 7172 (2023). DOI: 10.1038/s41598-023-34212-w.