

Classification of Pitayo Plant Varieties Using Multispectral Images

Clasificación de variedades de planta de pitayo usando imágenes multiespectrales

Rodrigo Rivera-Romero ^{*1}, Rosa Janette Pérez-Chimal ¹, Claudia Angélica Rivera-Romero ^{2,3}, Jorge Ulises Muñoz-Minjares ², Hayde Peregrina-Barreto ³, Humberto Pérez-Espinosa ³, and Iván Alfonso Reyes-Portillo ²

¹ Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica, Posgrado en Ingeniería para la Innovación Tecnológica, Ramón López Velarde # 801, Centro, Zacatecas, Zac., México, 98000.

{r.rivera, r.perez}@uaz.edu.mx

² Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica, Plantel Jalpa, Libramiento Jalpa Km., Fraccionamiento Solidaridad, Jalpa, 156+380, Jalpa, Zac., 99601, México.

{c.a.riveraromero, ju.munoz}@uaz.edu.mx

³ Instituto Nacional de Astrofísica, Óptica y Electrónica, Coordinación de Ciencias Computacionales, Luis Enrique Erro #1, Tonantzintla, Puebla, México, 72840.

{hperegrina, humbertop}@inaoep.mx, ivan.reyes@upslp.edu.mx

Abstract

This study addresses the classification of *Stenocereus queretaroensis* (pitayo) varieties according to fruit color using multispectral images obtained with a DJI Mavic 3M drone. A dataset with spectral features was built to train five machine learning models. The best results were achieved with the Decision Tree and Logistic Regression models, reaching an accuracy of 70%, demonstrating that the integration of multispectral imagery, NDVI, and artificial intelligence represents a promising tool for agricultural monitoring and the characterization and classification of plants.

Keywords— *Stenocereus queretaroensis*, multispectral imaging, vegetation indices, color spaces, NDVI images

Resumen

Este estudio aborda la clasificación de variedades de *Stenocereus queretaroensis* (pitayo) según el color del fruto mediante imágenes multiespectrales obtenidas con un dron DJI Mavic 3M. Se construyó un conjunto de datos con características espectrales para entrenar cinco modelos de aprendizaje automático. Los mejores resultados se lograron con el Árbol de Decisión y la Regresión Logística, alcanzando una exactitud del 70 %, evidenciando que la integración de imágenes multiespectrales, NDVI e inteligencia artificial son herramientas prometedoras para el monitoreo agrícola y la caracterización de plantas.

Palabras clave— *Stenocereus queretaroensis*, imágenes multiespectrales, índices de vegetación, espacios de color, imágenes NDVI

I. Introducción

El cultivo de *Stenocereus queretaroensis* (pitayo) ha despertado un creciente interés por su valor comercial, su potencial agroindustrial y su notable adaptación a climas semiáridos.

Diversos estudios han contribuido al entendimiento de esta especie desde perspectivas ecológicas, fisiológicas y tecnológicas. En [1] evaluaron el potencial reproductivo de esta especie en parcelas del municipio de Tabasco, Zacatecas, determinando que su éxito reproductivo depende de la disponibilidad de agua y de condiciones ambientales específicas, lo cual aporta bases para su conservación

* Autor de correspondencia

y aprovechamiento. Por su parte, en [2] analizaron fenotipos de pitaya de distintos colores, destacando que las variedades rojas presentan mejores atributos de firmeza y peso, lo que refuerza la importancia de la caracterización morfológica y físico-química para la selección de ejemplares.

Otros autores, como [3], estudiaron la composición química de los frutos de *Stenocereus thurberi*, evidenciando que el color del fruto se asocia con su contenido mineral y antioxidante. De manera complementaria, en [4] enfatizaron la viabilidad del cultivo de *S. queretaroensis* en regiones áridas y su potencial para la agricultura sostenible con bajos insumos de agua y energía. En el ámbito tecnológico, en [5] se exploró el uso del dron DJI Mavic 3 Multispectral para la generación de índices espectrales como NDVI (Índice de Vegetación de Diferencia Normalizada), NDRE y NDWI, demostrando la capacidad de estas herramientas para evaluar la salud de la vegetación mediante sensores multispectrales.

Asimismo, en [6] aplicaron esta tecnología al monitoreo de cultivos de papa, logrando identificar condiciones de estrés y deficiencias nutricionales a partir de imágenes RGB y NIR. Estos estudios evidencian el potencial de los drones y la teledetección multispectral en la agricultura de precisión. En cuanto a la caracterización del fruto, en [7] analizaron pigmentos y antioxidantes en tres variedades de *S. queretaroensis*, relacionando sus propiedades químicas con su valor nutricional. Finalmente, en [8] desarrollaron un sistema de clasificación de frutos de café mediante procesamiento digital de imágenes, obteniendo un 96.88 de precisión, lo que demuestra la eficacia de las técnicas de visión artificial y el aprendizaje automático en la clasificación agrícola.

En conjunto, estos antecedentes respaldan la necesidad de aplicar herramientas de visión computacional y análisis espectral en el estudio del pitayo. La identificación del color del fruto representa un desafío de ingeniería relevante, ya que las diferencias entre variedades no son perceptibles en etapas juveniles. Por lo tanto, el objetivo de este trabajo es desarrollar un modelo de clasificación temprana de variedades de *Stenocereus queretaroensis* en función del color de su fruto, utilizando imágenes RGB y NDVI obtenidas mediante la cámara multispectral de un dron y procesadas con técnicas de aprendizaje automático.

En este trabajo, se presentan los primeros resultados derivados del análisis de imágenes multispectrales para la identificación de las variedades de las plantas de *Stenocereus queretaroensis*. En esta propuesta se trabajó con imágenes multispectrales NDVI, RED y NIR generadas por software propietario del dispositivo de captura y la generación de nuevas imágenes NDVI creadas por el procesamiento con imágenes RED y NIR. Por estos medios, se extrajeron las características espectrales formadas con los




Figura 1: Cultivo de plantas de pitayo y la distribución de las plantas para la adquisición de las imágenes multispectrales por planta.

valores de los píxeles de las imágenes para lograr diferenciar las variedades de plantas. Estas características fueron probadas con cinco modelos de aprendizaje automático, de los cuales dos modelos destacaron por su desempeño y estabilidad, alcanzando niveles de exactitud cercanos al 70 % en los escenarios de clasificación binaria. Con estos resultados se evidencia que la información multispectral constituye una herramienta prometedora para el manejo de plantas y su caracterización entre variedades.

II. Metodología

El desarrollo de este estudio se estructuró en etapas que permitieron abordar de forma sistemática la clasificación de variedades de pitayo a partir de imágenes multispectrales.

II.1. Muestreo y adquisición de las imágenes multispectrales

El estudio se realizó en un huerto ubicado en la comunidad de Guadalupe Victoria, municipio de Jalpa, Zacatecas, México (21.717515° N, 102.976155° W), a una altitud aproximada de 1,750 m s.n.m. El sitio presenta un clima semiárido, con temperaturas que oscilan entre 20 y 33 °C. El huerto cuenta con un total de 143 plantas de *Stenocereus queretaroensis*, de las cuales se seleccionaron 109 ejemplares para el muestreo, considerando su estado de desarrollo y salud. Estas tienen una edad aproximada de cuatro años y presentan una distribución equilibrada de las tres variedades de fruto que se buscan identificar: rojo, naranja y amarillo. En la Figura 1, se presenta la imagen general del huerto y la vista aérea de la misma, donde se aprecia la disposición e identificación de cada planta seleccionada para el estudio.

Las imágenes se capturaron utilizando un dron DJI Mavic 3M [9], equipado con una cámara RGB de 20 megapíxeles con sensor CMOS de 4/3" y un sistema multispectral formado por cuatro cámaras independientes que registran información en las bandas verde (560 nm), roja (650 nm), borde rojo (730 nm) e infrarrojo cercano o NIR (860 nm) de una forma estática a una distancia




Figura 2: Procedimiento de captura de cada planta de pitayo, considerando la altura en función de una distancia promedio (1 a 4 metros) para lograr obtener la imagen completa del pitayo.

del pitayo. Lo que permite la adquisición simultánea de imágenes en espacio de color RGB e imágenes multiespectrales de alta resolución. Estas características permiten el análisis de las plantas para el cálculo de índices de vegetación, como el NDVI entre otros y el estudio de la variabilidad espectral entre variedades de plantas basados en el color de fruto.

El muestreo se realizó mensualmente de enero a mayo, bajo condiciones adecuadas de iluminación. Debido a las diferencias en altura y desarrollo entre las plantas de *Stenocereus queretaroensis*, la distancia del dron respecto a cada planta se ajustó individualmente, con el propósito de mantener una vista perpendicular y un campo de visión uniforme en todas las capturas. Cabe mencionar que el dron no se utilizó en vuelo autónomo, sino como plataforma estacionaria de captura, posicionándolo manualmente a distintas alturas y orientaciones según las características de cada ejemplar. Como se muestra en la Figura 2, la toma de imágenes se efectuó del lado iluminado de cada planta y a una altura media entre la base y la parte superior, garantizando una representación completa de su estructura y la homogeneidad espacial de las imágenes adquiridas.

El software del dron DJI Mavic 3M genera automáticamente composiciones del NDVI a partir de las bandas espectrales capturadas por el sensor multiespectral. Estas composiciones, junto con las imágenes RGB, se muestran en la Figura 3, la cual presenta los diferentes tipos de imágenes proporcionadas por el sistema del dron (RGB, Verde, Rojo, Borde Rojo, NIR y NDVI automático).

Además, se realizó el cálculo del NDVI mediante procesamiento digital de imágenes, utilizando las bandas NIR y Roja obtenidas por el sensor multiespectral. El cálculo del NDVI se basa en la ecuación 1 [10].




Figura 3: Imágenes generadas por el dron DJI Mavic 3M: RGB, NDVI automático, Verde (Green), Infrarrojo Cercano (NIR), Rojo (Red) y Borde Rojo (RedEdge).

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (1)$$

donde NIR representa la reflectancia en la banda del infrarrojo cercano y corresponde a la reflectancia en la banda roja del espectro visible. El valor resultante de NDVI varía entre -1 y $+1$, donde los valores cercanos a -1 indican superficies sin vegetación o con baja actividad fotosintética, y los valores próximos a $+1$ reflejan alta densidad vegetal y vigor biológico. Por lo tanto, se obtuvo un nuevo conjunto de datos complementario basado en el cálculo del NDVI para obtener valores por píxel de forma independiente a los datos generados por el dron. La Figura 4 muestra una comparación visual entre el NDVI generado automáticamente por el sistema del dron y el NDVI calculado mediante procesamiento digital, en la que se aprecia una mayor variación en el contraste espectral y una mayor riqueza de información radiométrica en el método personalizado. Esta comparación permitió evaluar la calidad espectral y la precisión espacial entre ambos enfoques, además de ampliar la base de datos empleada en los análisis de clasificación y caracterización de las plantas.

II.2. Región de interés y extracción de características

Se identificaron tres puntos principales, considerando las regiones de interés (región basal o tallo, región media y región superior) en cada una de las plantas de pitayo. Se extrajo un punto de interés central de cada imagen NDVI generada, definido como un nuevo conjunto de datos. Estos datos se consideraron como nuevas características principales de las imágenes [11]. Esta distribución permitió representar diferencias estructurales verticales y capturar variaciones espectrales asociadas al desarrollo y densidad del tejido vegetal. Los valores espectrales de cada punto (base, medio y superior) fueron extraídos




Figura 4: a) Imagen NDVI con las regiones de interés para identificar los puntos centrales de cada región en formato JPG generado por el software del dron, b) imagen NDVI calculada con los puntos de interés en formato TIFF, obtenido mediante la ecuación basada en las bandas NIR y Rojo del sistema multispectral.

y almacenados en otro nuevo conjunto de datos junto con el identificador de la planta y variedad y el tipo de imagen (NDVI automático y NDVI calculado). La Figura 4 muestra la ubicación de las regiones de interés (ROIs) en las imágenes NDVI, donde se aprecian los puntos específicos correspondientes a cada zona estructural de las plantas.

A partir del muestreo realizado entre enero y mayo, se registraron 109 ejemplares de *Stenocereus queretaroensis*, de los cuales 72 correspondieron a la variedad roja, 22 a la variedad naranja y 15 a la variedad amarilla. Con el propósito de equilibrar el número de muestras por clase y garantizar un análisis estadístico uniforme, se implementó un proceso de aumento de datos (data augmentation en inglés) para las variantes con menor representación. Este procedimiento consistió en extraer múltiples puntos dentro de las mismas ROIs de cada planta de pitayo, preservando la representatividad espectral del ejemplar y ampliando el conjunto de datos sin introducir ruido o redundancia significativa. De este modo, se homogenizó la cantidad de registros para las tres categorías de color consideradas (rojo, amarillo y naranja), en todas las imágenes NDVI.

Con los puntos extraídos se generó un nuevo conjunto de datos integrando el identificador de la planta (variedad de color), el tipo de imagen y los valores de los píxeles extraídos de cada ROI. Esta organización facilitó el manejo posterior de la información y la trazabilidad del proceso. A partir de este punto el procesamiento de los datos se efectuó mediante dos métodos diferenciados según el tipo de imagen:

- **Método 1.** De las imágenes NDVI generadas por software, los valores obtenidos dentro de cada ROI se encontraban en formato RGB, teniendo como base estos valores y con el propósito de analizar la influencia del espacio de color en la respuesta espectral y mejorar la sensibilidad de los clasificadores, se efectuaron conversiones a distintos espacios de color,

transformando las imágenes desde el formato RGB hacia HSV (Hue, Saturation, Value), CIE Lab* (Luminosidad, eje verde, eje azul), YCbCr (Luminancia y componentes de crominancia) y escala de grises [12]. Posteriormente, los valores en escala de grises fueron reescalados linealmente conforme a la ecuación 2, la cual permite convertir un rango discreto de intensidad (por ejemplo, 0–255 o 0–180) al intervalo normalizado de NDVI entre -1 y +1. Finalmente, se aplicó una normalización general de tipo reescalado lineal sobre los valores derivados de cada espacio de color (Figura 5), con el fin de escalar todas las variables al mismo rango de comparación y evitar sesgos en el proceso de entrenamiento de los modelos de clasificación [10].

$$NDVI = 2 \times \left(\frac{I - \min}{\max - \min} \right) - 1 \quad (2)$$

donde I representa el valor de intensidad del píxel en escala de grises, mientras que \min y \max son los valores mínimo y máximo posibles en la escala original correspondientes a las ROIs base, medio y superior.

- **Método 2.** En el segundo enfoque, correspondiente a las NDVI calculadas, los valores obtenidos de las imágenes derivadas de las bandas NIR y Roja ya se encontraban en escala de grises, por lo que se aplicó la misma ecuación de normalización para mantener la consistencia entre ambos conjuntos de datos (Figura 6). Este método permitió obtener valores NDVI independientes del procesamiento automático del dron, proporcionando un control más preciso sobre la calibración radiométrica y la respuesta espectral por píxel.

En las figuras 5 y 6 se muestran los diagramas esquemáticos del procesamiento y extracción de características aplicado a las imágenes multispectrales para cada método. En el Método 1, se ilustra el flujo correspondiente a las NDVI automáticas, que incluye la conversión de RGB a escala de grises y la transformación a valores NDVI, y la conversión a diferentes espacios de color HSV, CIE Lab y YCbCr [13]. En el Método 2, se representa el proceso aplicado a las imágenes NDVI calculadas, donde los valores se derivan directamente de las bandas multispectrales originales mediante la ecuación estándar (ecuación 1).

Finalmente, todos los valores NDVI resultantes fueron normalizados y organizados en un conjunto de datos final, para su integración en diferentes modelos de aprendizaje automático. Los datos multimodales generados con el Método 1, se sometieron a un proceso de normalización para homogeneizar las escalas de los datos, minimizar el sesgo entre conjuntos y garantizar la estabilidad de los clasificadores empleados en las etapas posteriores de análisis.



Figura 5: Metodología para la adquisición de datos multimodales con las imágenes en diferentes espacios de color y las imágenes NDVI automáticas (Método 1).




Figura 6: Metodología para la adquisición de datos de las imágenes NDVI calculadas mediante las imágenes NIR y Rojo (Método 2).

II.3. Modelos de aprendizaje automático

Para el entrenamiento y evaluación de los nuevos conjuntos de datos, se propone el uso de modelos de aprendizaje automático de forma binaria como una primera fase de prueba experimental para los datos generados con el Método 1, con la finalidad de identificar las variedades de las plantas de pitayo de acuerdo al color de fruto. Para estos modelos, se propuso una división del conjunto de datos, de un 80 % de las muestras para el entrenamiento y validación y el 20 % restante para las pruebas, para garantizar la representatividad proporcional de cada una de las clases de color. Se emplearon cinco algoritmos de clasificación supervisada ampliamente utilizados en problemas de reconocimiento de patrones descritos a continuación.

- El algoritmo KNN clasifica las muestras en función de la distancia euclidiana entre vectores de características, asignando la clase predominante entre los k vecinos más cercanos. Este método no requiere una fase de entrenamiento compleja, pero su desempeño depende significativamente de la selección óptima del parámetro k y del tipo de métrica utilizada [12, 14].
- Las Máquinas de Soporte Vectorial (SVM) construyen hiperplanos de separación que maximizan el margen entre clases, utilizando funciones kernel (lineal, polinómico o radial) para proyectar los datos en espacios de mayor dimensión cuando las fronteras no son linealmente separables. Su robustez y capacidad de generalización las hacen adecuadas para conjuntos de datos con alta dimensionalidad [15, 12].

- El método Random Forest (RF) combina múltiples árboles de decisión entrenados de manera aleatoria sobre subconjuntos del conjunto de datos, integrando sus predicciones mediante votación. Este enfoque de aprendizaje por ensamble mejora la estabilidad y reduce la varianza del modelo, ofreciendo un equilibrio entre precisión y resistencia al sobreajuste (overfitting en inglés) [15, 16].
- La Regresión Logística (LR), aunque originalmente desarrollada para problemas binarios, se adapta eficazmente a clasificación multiclase mediante estrategias de one-vs-all en inglés. Modela la probabilidad de pertenencia de una muestra a una clase específica utilizando la función sigmoide, lo que permite interpretar los resultados de forma probabilística [17, 18].
- El Árbol de Decisión (DT) genera una estructura jerárquica de decisiones mediante reglas de partición basadas en medidas de pureza como la ganancia de información o el índice Gini. Este modelo es intuitivo, de fácil interpretación y útil para identificar las variables más influyentes en el proceso de clasificación [19, 20].

Los modelos obtenidos fueron comparados según su precisión y capacidad de generalización, con el propósito de identificar el algoritmo con mejor desempeño en la clasificación de las variedades de *Stenocereus queretaroensis*.

II.4. Evaluación de desempeño de los modelos

El rendimiento de los clasificadores se evaluó utilizando métricas estándar del aprendizaje supervisado, como la exactitud (accuracy en inglés), la precisión (precision en inglés), sensibilidad (recall en inglés) y puntuación F1 (F1-score en inglés). Cada una de estas métricas indica la eficacia del modelo: i) accuracy: cuantifica la proporción de predicciones correctas respecto al total de observaciones, ii) precision: mide la exactitud de las predicciones positivas, es decir, qué porcentaje de los elementos clasificados como positivos son realmente correctos, iii) recall: evalúa la capacidad del modelo para identificar correcta-

Tabla 1: Métricas de evaluación de los modelos de clasificación, dónde se definen del cálculo de las matrices de confusión considerando los valores de *TP* - verdaderos positivos, *TN* - verdaderos negativos, *FP* - falsos positivos, *FN* - falsos negativos.

Parámetro	Fórmula
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Precision	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$
F1-score	$2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

mente todos los elementos positivos reales, y iv) F1-Score: combina la precisión y recall en una media armónica que refleja el equilibrio entre ambos. Las fórmulas correspondientes y la descripción de los parámetros involucrados se presentan en la Tabla 1, la cual resume las métricas utilizadas para la evaluación cuantitativa del desempeño de los modelos de clasificación.

Adicionalmente, se calculó la matriz de confusión, para tener una representación bidimensional que presenta los aciertos (verdaderos positivos) y errores (verdaderos negativos) por clase, facilitando el análisis detallado del comportamiento del modelo al clasificar por variedad de planta con base al color del fruto (fruto rojo, fruto amarillo y fruto naranja). Estos parámetros permiten cuantificar la exactitud global, la sensibilidad por clase y la consistencia entre las clases predichas y las clases reales.

Los procedimientos descritos permitieron generar los primeros resultados de clasificación con el conjunto de datos generador con el Método 1 como una primer fase experimental. Entre los resultados, se busca una base sólida con el uso de los modelos de aprendizaje automático para determinar su aplicabilidad en la identificación de variedades de pitayos.

III. Resultados

Se realizaron tres procesos de clasificación binaria para las combinaciones de colores amarillo–naranja, amarillo–rojo y naranja–rojo, con el propósito de evaluar la capacidad de los modelos entrenados a partir de los valores NDVI y los espacios de color. Entre los resultados obtenidos, la clasificación amarillo–naranja presentó el desempeño más equilibrado y estable en comparación con las otras dos combinaciones, por lo que se seleccionó como caso representativo para el análisis visual y la interpretación de las métricas de desempeño.

Matriz de Confusión - Logistic					
True Class	AMARILLO	33	27	55.0%	45.0%
	NARANJA	14	46	76.7%	23.3%
		70.2%	63.0%		
		29.8%	37.0%		
	AMARILLO	NARANJA	Predicted Class		

Figura 7: Matriz de confusión del modelo de Regresión Logística para la clasificación binaria amarillo–naranja.

		Matriz de Confusión - Tree			
True Class	AMARILLO	36	24	60.0%	40.0%
	NARANJA	16	44	73.3%	26.7%
			69.2%	64.7%	
			30.8%	35.3%	
		AMARILLO	NARANJA	Predicted Class	

Figura 8: Matriz de confusión del modelo de árbol de decisión (Decision Tree) para la clasificación binaria amarillo–naranja.

En la Figura 7 se presenta la matriz de confusión del modelo Árbol de Decisión (Tree en inglés), donde se observa una distribución equilibrada de aciertos en ambas clases. El modelo logró una correcta identificación de la mayoría de las muestras amarillas y naranjas, mostrando una proporción similar de verdaderos positivos y negativos.

Por su parte, la Figura 8 muestra la matriz de confusión del modelo de Regresión Logística, que también alcanzó resultados satisfactorios, aunque con una ligera reducción en la precisión respecto al modelo Árbol de Decisión. En ambos casos, los errores de clasificación se concentraron en las muestras con valores espectrales intermedios, lo que indica una posible superposición entre las características de ambas variedades.

La Figura 9 presenta las curvas ROC (Receiver Operating Characteristic en inglés) correspondientes a los clasificadores evaluados. Estas curvas permiten visualizar la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR) para distintos umbrales de decisión. Un mayor área bajo la curva (AUC) representa un mejor desempeño del modelo. En este caso, los clasificadores Árbol de Decisión y Regresión Logística

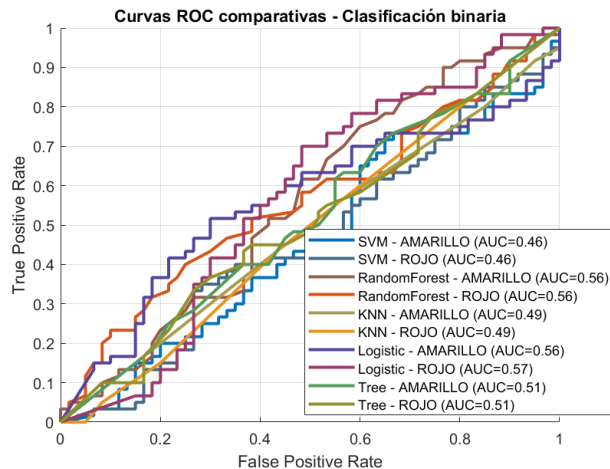


Figura 9: Curvas ROC (Receiver Operating Characteristic) y AUC (Area Under curve), métricas para evaluar la capacidad de un modelo de clasificación binaria. El resultado es un rendimiento aleatorio aproximado para los modelos de regresión logística y el árbol de decisión.

exhibieron las curvas más próximas al vértice superior izquierdo, lo que refleja una mejor capacidad de discriminación entre las clases amarillo y naranja en comparación con los demás algoritmos.

La Figura 10 muestra la comparación general de métricas de clasificación (Accuracy, Precision, Recall y F1-Score) obtenidas por los diferentes métodos supervisados. De manera general, los modelos Árbol de Decisión y Regresión Logística mantuvieron valores más altos en todas las métricas, evidenciando un equilibrio entre la cantidad de aciertos totales y la capacidad de detección de cada clase. En contraste, los métodos KNN, SVM y RF presentaron mayores variaciones entre precisión y sensibilidad, lo que indica que su desempeño fue más dependiente de la distribución espectral de las muestras.

En cuanto a las otras dos clasificaciones binarias (amarillo-rojo y naranja-rojo), los resultados mostraron un comportamiento menos equilibrado, con una mayor tendencia del modelo a clasificar correctamente solo una de las dos clases. En particular, las muestras de color rojo fueron las que presentaron mayor confusión con las naranjas, posiblemente debido a la similitud de sus respuestas espectrales en las bandas visibles y del infrarrojo cercano.

Estos resultados confirman que la separación entre las clases amarillo-naranja representa el escenario más adecuado para el análisis comparativo de los clasificadores y la validación del sistema de identificación de variedades.




Figura 10: Comparación de las métricas de desempeño (Accuracy, Precision, Recall y F1-Score) para los modelos de clasificación evaluados.

IV. Conclusión

Este estudio demostró la utilidad de caracterizar las imágenes multiespectrales para su uso con modelos de aprendizaje supervisado para la identificación de variedades de *Stenocereus queretaroensis* (pitayo) en función del color del fruto. Mediante la integración de información multimodal con valores en diferentes espacios de color y un índice de vegetación, es posible discriminar entre variedades de plantas, lo cual puede ser de apoyo también para determinar otras condiciones en las plantas.

Los modelos de Árbol de Decisión y Regresión Logística alcanzaron los mejores resultados, con una exactitud cercana al 70 %, evaluada con métricas como el F1-score y recall. Esto demuestra que los métodos estadísticos y basados en árboles pueden capturar adecuadamente patrones espectrales en etapas de desarrollo de las plantas.

En el trabajo a futuro se busca mejorar estos resultados, aumentando el número de experimentos y ampliando el conjunto de datos multimodales con el cálculo de más índices de vegetación partiendo de las imágenes en la banda verde, rojo, borde y NIR. Entre las limitaciones observadas en esta primera fase, el tamaño del conjunto de datos y las condiciones controladas de captura que restringieron algunos parámetros a definir de forma constante dentro de las condiciones experimentales, como el tamaño de las plantas y el cuidado controlado en los escenarios agrícolas más complejos. Por lo tanto, en este primer reporte, el enfoque se centró sólo en la clasificación binaria de las variedades disponibles.

Como trabajo futuro, se propone ampliar el conjunto de datos incorporando variabilidad y distintos estados fenológicos de la planta en desarrollo, esto con la finalidad de hacer un diagnóstico de enfermedades o plagas,

así como extender el análisis a un enfoque multiclase. Además, es posible integrar por medio de las imágenes características morfológicas, patrones binarios o de textura, con base al análisis de regiones de interés para buscar mejores características.

Adicionalmente, se busca validar los modelos en condiciones reales de campo y avanzar hacia el desarrollo de sistemas automatizados de monitoreo, que sirvan como herramientas de apoyo en la domesticación y mejoramiento genético de la planta del pitayo, para lograr su cuidado y protección así como su reproducibilidad, siendo un cultivo endémico de alto consumo y valor agroindustrial.

Agradecimientos

La Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) financió esta investigación mediante el proyecto de la Convocatoria de Ciencia de Frontera con el identificador CF-2023-I-2021. Además, agradecemos por las becas de maestría y doctorado, otorgadas a Rodrigo Rivera-Romero (No. CVU 1017277) y a Rosa Jannette Pérez Chimal (No. CVU 290119), respectivamente.

V. Referencias

Referencias

- [1] O. Solís-Márquez et al. «Potencial reproductivo de *Stenocereus queretaroensis* (Cactaceae) de San José de Cosalima, Zacatecas». En: *Revista Mexicana de Biodiversidad* 89.2 (2018), págs. 553-563.
- [2] Eduardo Campos-Rojas et al. «Evaluación de plantas de pitaya (*Stenocereus* spp) de poblaciones naturales de Monte Escobedo, Zacatecas». En: *Revista Chapingo. Serie Horticultura* 17.3 (2011), págs. 245-252. ISSN: 1027-152X.
- [3] Jeny Hinojosa-Gómez y María D. Muy-Rangel. «Caracterización fisicoquímica y compuestos bioactivos en los frutos de pitaya (*Stenocereus thurberi*) de cuatro colores». En: *TIP. Revista especializada en ciencias químico-biológicas* 26 (2023), e561.
- [4] Eulogio Pimienta-Barrios et al. «Ethnobotany, Productivity, and Ecophysiology of Pitaya (*Stenocereus queretaroensis*)». En: *Journal of the Professional Association for Cactus Development* 2 (1997), págs. 29-47.
- [5] Oren Nardi. *Developing High-Resolution Spectral Indices from Mavic 3M Multispectral Imagery*. Remote sensing study at Cal Poly Humboldt using DJI Mavic 3M. 2024.
- [6] Viviana A. Berrío, Jemay T. Mosquera y Diego F. Alzate. «Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión». En: *@LIMENTECH, Ciencia y Tecnología Alimentaria* 13.1 (2015), págs. 28-40. ISSN: 1692-7125.
- [7] Chelsy Denise Gutiérrez Valdivia, Jacinto Bañuelos Pineda y Lucía Barrientos Ramírez. «Extracción, cuantificación y caracterización de betacianinas y betaxantinas en pulpa de tres variedades de pitaya (*Stenocereus queretaroensis* (Weber) Buxb)». En: *AGRIS* (2020).
- [8] Zulma Sandoval y Flavio Prieto. «Procesamiento de imágenes para la clasificación de café cereza». En: *Prospectiva* 7.1 (2009), págs. 67-73. ISSN: 1692-8261.
- [9] DJI. *DJI Mavic 3M – Specifications*. Accessed: 2025-10-15. DJI. 2025. URL: <https://enterprise.dji.com/mavic-3-m/specs>.
- [10] J. W. Rouse et al. «Monitoring vegetation systems in the Great Plains with ERTS». En: *Third Earth Resources Technology Satellite-1 Symposium*. Vol. 1. NASA SP-351. Washington, D.C.: NASA, 1974, págs. 309-317.
- [11] Libao Zhang y Shiyi Wang. «Region-of-Interest Extraction Based on Local-Global Contrast Analysis and Intra-Spectrum Information Distribution Estimation for Remote Sensing Images». En: *Remote Sensing* 9.6 (2017), pág. 597. DOI: 10.3390/rs9060597.
- [12] Claudia Angélica Rivera-Romero et al. «Recognition in the early stage of powdery mildew damage for cucurbit plants using spectral signatures». En: *Biosystems Engineering* 252 (2025), págs. 144-158. ISSN: 1537-5110.
- [13] Claudia Angélica Rivera-Romero et al. «Early-Stage Identification of Powdery Mildew Levels for Cucurbit Plants in Open-Field Conditions Based on Texture Descriptors». En: *Inventions* 9.1 (2024). ISSN: 2411-5134.
- [14] Nouf Alhassoun et al. «Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications made to enhance the exact kNN techniques». En: *Journal of Big Data* 11.1 (2024), págs. 1-36.
- [15] Trevor Hastie, Robert Tibshirani y Jerome Friedman. «A comprehensive comparison of random forests and support vector machines». En: *Statistics and Computing* 9.3 (2009), págs. 1-20.

- [16] H. Chen et al. «Comparative Analysis of Logistic Regression, Gradient Boosted Trees, Support Vector Machine, and Random Forest». En: *International Journal of Nutritional Research and Development* (2023).
- [17] Zhou Zhang et al. «Comparison between traditional logistic regression and machine learning models for clinical predictions». En: *Frontiers in Medicine* 11 (2024), pág. 1496869.
- [18] Maher Maalouf. «Logistic regression in data analysis: An overview». En: *International Journal of Data Analysis Techniques and Strategies* 3.3 (2011), págs. 281-299.
- [19] Haoran Liu et al. «Decision trees: from efficient prediction to responsible AI». En: *Nature Machine Intelligence* 5 (2023), págs. 611-619.
- [20] Danladi Moses Mienye y Nober T Jere. «A Survey of Decision Trees: Concepts, Algorithms and Applications». En: *International Journal of Computer Science and Information Security* 21.6 (2023), págs. 1-12.