



Scientia Agropecuaria

Web page: <http://revistas.unitru.edu.pe/index.php/scientiaagrop>

Facultad de Ciencias
Agropecuarias

Universidad Nacional de
Trujillo

RESEARCH ARTICLE



Identification of the phytosanitary status of trees using machine learning and very high spatial resolution images

Identificación del estado fitosanitario de árboles mediante aprendizaje automático e imágenes de muy alta resolución espacial

Juan Carlos Díaz-Rivera^{1,*} ; Carlos Arturo Aguirre-Salado² ; Catarina Loredo-Osti¹ ; Martín Escoto-Rodríguez¹ 

¹ Facultad de Agronomía y Veterinaria, Universidad Autónoma de San Luis Potosí, Soledad de Graciano Sánchez, SLP 78321, México.

² Facultad de Ingeniería, Universidad Autónoma de San Luis Potosí, San Luis Potosí, SLP 78280, México.

* Corresponding author: juancarlosdiazrivera10@gmail.com (J. C. Díaz Rivera).

Received: 12 October 2023. Accepted: 24 March 2024. Published: 8 April 2024.

Abstract

Tree diseases contribute to significant economic and food losses in the agricultural sector. Early detection of phytosanitary problems in trees with non-destructive methods is essential to guarantee sustainable orange production. This study presents the findings of a designed methodology conducted to identify diseased orange trees in an orchard situated in the citrus belt of Mexico, specifically in the Rioverde region of San Luis Potosí. To accomplish this, we captured images using a multispectral camera with very high spatial resolution, which was mounted on an unmanned aerial vehicle. These images were used to construct a georeferenced orthomosaic of the orchard. Six thematic classes were established to distinguish various health levels among the trees. We employed several supervised classification algorithms at the pixel level, including Random Forest (RF), K-Nearest Neighbor (KNN), Spectral Angle Mapper (SAM), Support Vector Machine (SVM), and Maximum Likelihood (ML). Considering the classification accuracy achieved by each algorithm, they can be ranked as follows: Maximum Likelihood (ML) with 88.10%, Support Vector Machine (SVM) with 77.38%, Spectral Angle Mapper (SAM) with 76.19%, K-Nearest Neighbor (KNN) with 64.68%, and Random Forest (RF) with 61.90%. These results successfully identified the phytosanitary status of all the trees in the orchard with an acceptable level of accuracy, providing valuable management information for the grower.

Keywords: precision agriculture; sick trees; citrus; Orange; Mexico; Unmanned aerial vehicle.

Resumen

Las enfermedades de los árboles contribuyen a importantes pérdidas económicas y de alimentos en el sector agrícola. La detección temprana de problemas fitosanitarios en árboles con métodos no destructivos resulta fundamental para garantizar la producción sostenible de naranja. Este trabajo presenta los resultados de una metodología diseñada para la identificación de árboles de naranja enfermos en una huerta ubicada en el cinturón cítrico de México, particularmente en la región de Rioverde, San Luis Potosí. Para ello, se tomaron imágenes con una cámara multispectral de muy alta resolución espacial instalada en un vehículo aéreo no tripulado con las que se construyó un ortomosaico georreferenciado. Se emplearon seis clases temáticas para identificar los diferentes niveles de sanidad. Se utilizaron diferentes algoritmos de clasificación supervisada a nivel píxel que incluyen Random Forest (RF), K-Nearest Neighbor (KNN), Spectral Angle Mapper (SAM), Support Vector Machine (SVM), y Maximum Likelihood (ML). Considerando la exactitud de clasificación obtenida por cada uno de los algoritmos, se pueden ordenar de la siguiente manera: Maximum Likelihood (ML) con un 88,10%, Support Vector Machine (SVM) con un 77,38%, Spectral Angle Mapper (SAM) con un 76,19%, K-Nearest Neighbor (KNN) con un 64,68% y Random Forest (RF) con un 61,90%. Los resultados permitieron identificar el estado fitosanitario de todos los árboles de la huerta, con una exactitud aceptable y representan información valiosa de manejo para el productor.

Palabras clave: agricultura de precisión; árboles enfermos; cítricos; naranja; México; vehículo aéreo no tripulado.

DOI: <https://doi.org/10.17268/sci.agropecu.2024.013>

Cite this article:

Díaz-Rivera, J. C., Aguirre-Salado, C. A., Loredo-Osti, C., & Escoto-Rodríguez, M. (2024). Identificación del estado fitosanitario de árboles mediante aprendizaje automático e imágenes de muy alta resolución espacial. *Scientia Agropecuaria*, 15(2), 177-189.

1. Introducción

La producción de naranja ha experimentado una tendencia decreciente en los últimos años (Spreen et al., 2020; Milind, 2023). Esta disminución puede atribuirse a múltiples factores, incluyendo los impactos del cambio climático (Ezrari et al., 2022), los brotes de enfermedades (Freitas et al., 2019) y la dinámica del mercado (Alzubi et al., 2023).

El cambio climático ha surgido como una amenaza significativa para la producción global de naranja, alterando los patrones de temperatura (Zabihi et al., 2016), precipitación (Balfagón et al., 2021) y humedad (Antolínez et al., 2022). Estos cambios perturban el delicado equilibrio necesario para un crecimiento y desarrollo óptimos de los árboles de naranja, lo que conduce a una disminución en los rendimientos y un aumento en la vulnerabilidad a las enfermedades (Godefroid et al., 2023).

Entre las enfermedades que afectan a los árboles de naranja, dos ejemplos destacados son el Huanglongbing (HLB) (Berk, 2016) y la tristeza de los cítricos (Hajeri & Yokomi, 2023). El Huanglongbing, también conocido como enverdecimiento de los cítricos, es una enfermedad bacteriana altamente destructiva que afecta a las plantas cítricas en todo el mundo. Se transmite principalmente por el psílido asiático de los cítricos, un pequeño insecto que se alimenta de los árboles cítricos y propaga las bacterias responsables de la enfermedad. El HLB causa graves daños a la industria de los cítricos al debilitar los árboles (Spreen et al., 2020), reducir la calidad de la fruta (Bassanezi et al., 2021; Tuwo et al., 2024) y, en última instancia, llevar a la muerte de los árboles (Xu et al., 2022). Por otro lado, la tristeza de los cítricos es una enfermedad viral que afecta a las plantas cítricas, especialmente a los árboles de naranja. Se transmite por los pulgones y causa una variedad de síntomas, incluyendo decoloración de las hojas (Atta et al., 2012), reducción del tamaño de la fruta (Braham et al., 2023) y mayor susceptibilidad a otras enfermedades.

La identificación y manejo de los árboles de naranja enfermos es crucial para mitigar el impacto de estas enfermedades en los huertos (Moriya et al., 2021). Los métodos tradicionales de detección de enfermedades se basan en la inspección visual realizada por seres humanos, lo cual puede ser tedioso y está sujeto a errores (Barman & Choudhury, 2022). Por otro lado, las técnicas de percepción remota, en combinación con algoritmos de aprendizaje automático, han demostrado un gran potencial para automatizar y mejorar los procesos de detección de enfermedades (Moussaid et al., 2020). Abdulridha et al. (2019) desarrollaron una técnica para detectar

cancro de los cítricos en diferentes etapas del desarrollo con la utilización de imágenes hiperespectrales obtenidas con UAV's y los métodos de función de base radial (RBF) y K-Nearest Neighbor. Ampatzidis et al. (2020) desarrollaron la aplicación Agrovie, basada en la nube de datos y la inteligencia artificial, con la cual desarrollaron mapas de salud a través de imágenes obtenidas por medio de UAV's. Chang et al. (2020) realizaron la caracterización de la enfermedad del reverdecimiento de los cítricos mediante la comparación de la forma del dosel y cuatro índices de vegetación de los árboles derivados de imágenes multiespectrales obtenidas de UAV's. El Imanni et al. (2023) mapearon la maleza que afecta a huertos de cítricos en Marruecos; en su trabajo combinaron imágenes multiespectrales obtenidas de UAV's e imágenes de Google Earth Engine. Utilizaron los algoritmos K-Nearest Neighbor y Random Forest para discriminar árboles de malezas. En la actualidad son escasos los trabajos que utilizan métodos de aprendizaje automático aplicados en imágenes de muy alta resolución espacial para detectar el estado fitosanitario de árboles de naranja, particularmente en México no se encontraron trabajos que utilicen esta metodología. El objetivo de este trabajo fue identificar árboles de naranja enfermos en un huerto ubicado en el Valle de Rioverde, San Luis Potosí, México, utilizando datos de alta resolución espacial recopilados mediante vuelos de vehículos aéreos no tripulados (UAV, por sus siglas en inglés). Para ello, se evaluó el desempeño de cinco algoritmos de aprendizaje automático los cuales incluyen Random Forest, K-Nearest Neighbor, Spectral Angle Mapper, Support Vector Machine y Maximum Likelihood.

2. Metodología

2.1. Área de estudio

La investigación se realizó en una huerta que se ubica dentro de una importante zona citrícola de más de 5000 ha en la zona centro del Valle de Rioverde, específicamente en el municipio de Ciudad Fernández, San Luis Potosí, México. El área experimental tiene la forma de un polígono irregular de aproximadamente 4 ha (Figura 1a). En esta región existen dos temporadas de cosecha, la primera en junio-julio y la segunda en agosto-septiembre. La parcela se riega mediante un sistema de aspersión que cubre las necesidades de cada árbol y la fuente de agua es un pozo que se encuentra dentro de la misma.

Se realizó un inventario de árboles de la huerta, en el que se registraron 632 árboles colocados en línea de 8 X 8 m (Figura 1a).

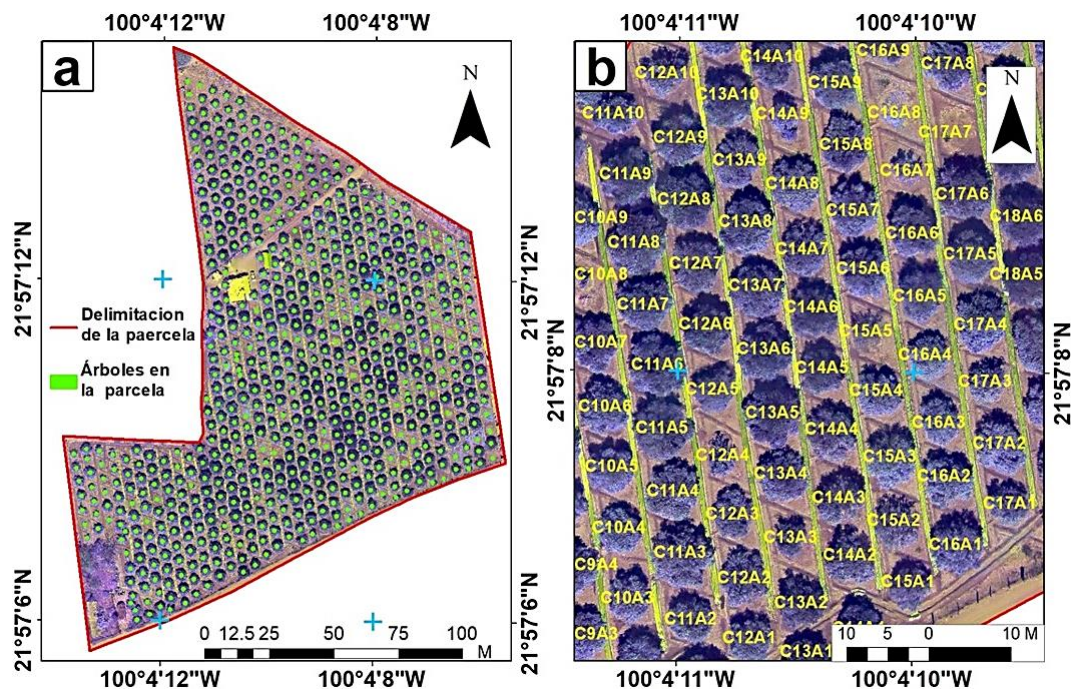


Figura 1. a) Inventario de árboles. b) Clave de identificación de árbol.

En este inventario se incluyeron los espacios en donde actualmente no hay árboles debido a que fueron cortados por el productor o se cayeron por enfermedad, ya que esos árboles son reemplazados constantemente. Cada árbol y espacio sin árbol se etiquetó con una clave de identificación compuesta por número de columna y número árbol generando 677 etiquetas, en la Figura 1b se realizó un acercamiento al inventario para apreciar de mejor manera la clave por árbol.

2.2. Descripción de la metodología

Este trabajo se desarrolló en ocho etapas (Figura 2): (1) adquisición y preprocesamiento de datos de imágenes multiespectrales, (2) generación del ortomosaico, (3) diseño del esquema de clasificación de la cobertura terrestre y selección de áreas de entrenamiento, (4) separación aleatoria de polígonos de entrenamiento y validación (5) selección y configuración de algoritmos, (6) clasificación de ortomosaico, (7) validación y evaluación de la precisión de los algoritmos y (8) determinación de la condición fitosanitaria por algoritmo para cada árbol.

2.3. Algoritmos empleados

2.3.1. Maximum Likelihood (ML)

El algoritmo de máxima verosimilitud asigna una etiqueta de clase a cada píxel en la imagen. El proceso comienza definiendo las clases de interés y recopilando muestras de entrenamiento que

representen cada clase empleando las bandas espectrales de la imagen. Cada muestra de entrenamiento contiene información sobre los valores de las bandas espectrales en una ubicación específica, y se etiqueta con la clase a la que pertenece. Luego, se construye un modelo de probabilidad para cada clase basado en las muestras de entrenamiento. El modelo asume que las bandas espectrales siguen una distribución de probabilidad específica para cada clase. El objetivo es encontrar los parámetros de estas distribuciones que maximicen la probabilidad de que los datos observados provengan de cada clase. Para un píxel dado, se calcula la probabilidad de que sus valores de bandas espectrales coincidan con las distribuciones de probabilidad de cada clase. Luego, el píxel se asigna a la clase con la probabilidad más alta (Sun et al., 2013). Algunas aplicaciones de este algoritmo incluyen el monitoreo de la sigatoka amarilla en banano (Calou et al., 2020), la detección y análisis de patrones de distribución espacial de malas hierbas en campos de cebolla (Rozenberg et al., 2021) entre otros.

2.3.2. Random Forest (RF)

Random Forest es un algoritmo no paramétrico de aprendizaje automático supervisado, que construye múltiples clasificadores de árboles de decisión, en el cual cada uno etiqueta un píxel con una clase determinada, la identidad final se basa en el voto más popular de todas las etiquetas de clase asignadas por los clasificadores individuales.

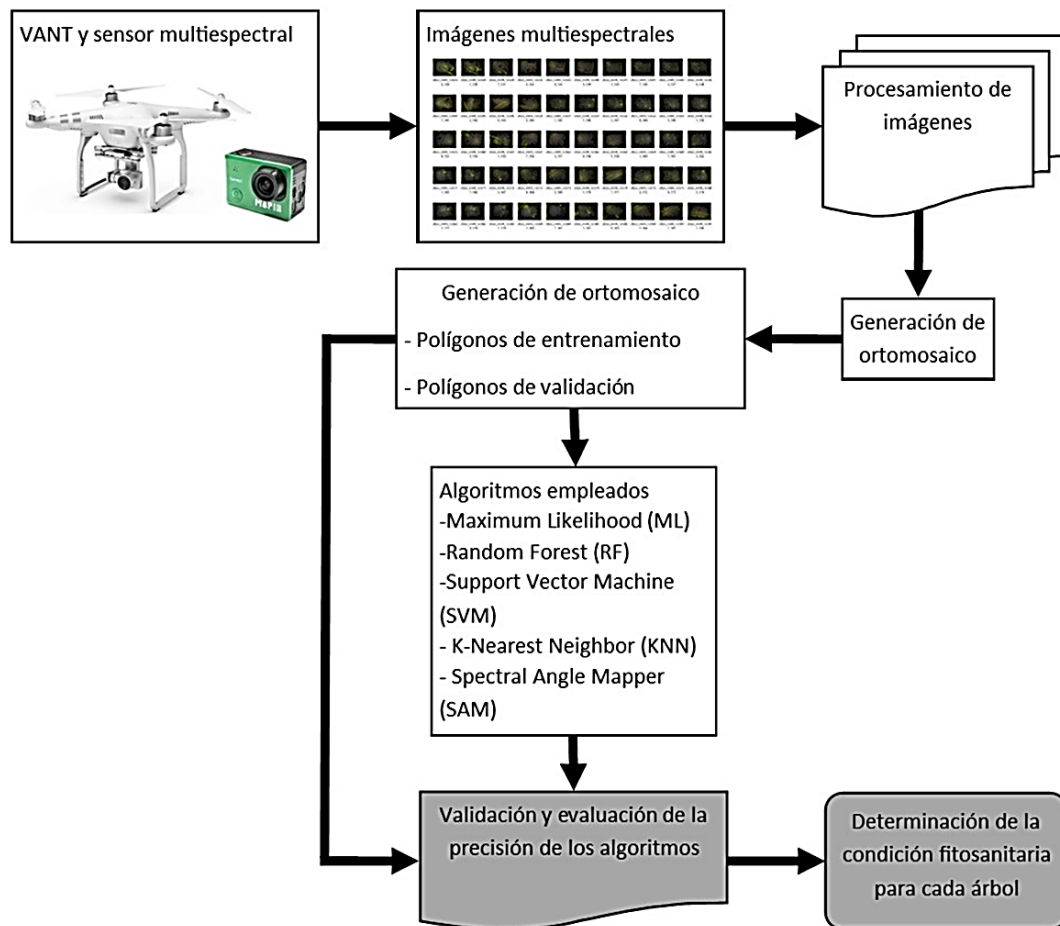


Figura 2. Diagrama de flujo de la metodología.

Cada árbol de decisión individual crece usando dos tercios diferentes de muestras de entrenamiento seleccionadas al azar a través del proceso de muestreo bootstrap; los datos de un tercio omitido en el análisis se utilizan para una estimación del error (Pal, 2005). Entre sus bondades se incluyen la capacidad de procesar conjuntos grandes de datos y de alta dimensión, ser resistente a valores atípicos y al ruido en los datos de entrenamiento, así como poseer una velocidad de entrenamiento rápida además de evitar el sobreajuste. Entre las aplicaciones se destacan el modelado de la estimación del coeficiente de cultivo de maíz bajo diferentes niveles de riego (Shao et al., 2021), la estimación de biomasa de una comunidad vegetal altoandina (Estrada-Zúñiga et al., 2022), la clasificación de tipos de bosques en ecosistemas en restauración (Scheeres et al., 2023), entre otros.

2.3.3. Support Vector Machine (SVM)

Support Vector Machine (SVM) es un algoritmo de aprendizaje supervisado utilizado tanto para clasificación como para regresión. Su objetivo principal es encontrar el hiperplano óptimo que mejor

separa las muestras de diferentes clases en un espacio dimensional. En un contexto de clasificación binaria, el hiperplano es una frontera que divide las clases en dos regiones distintas. El hiperplano óptimo es aquel que maximiza el margen entre las muestras más cercanas de ambas clases, también conocidas como vectores de soporte. Estos vectores de soporte son los puntos de datos más críticos, ya que determinan completamente la posición y orientación del hiperplano (Huang et al., 2002). Dentro de los estudios relevantes con SVM, destacan la detección de Huanglongning en árboles de cítricos a través de imágenes multispectrales obtenidas con UAV's (García-Ruiz et al., 2013), la detección de enfermedades en cítricos basada en síntomas mediante el uso de varios algoritmos de clasificación (Ali et al., 2017), la detección del enverdecimiento de los cítricos con imágenes multispectrales de UAV (Lan et al, 2020), etc.

2.3.4. k-Nearest Neighbor (kNN)

kNN (k-Nearest Neighbor) es un algoritmo de aprendizaje supervisado utilizado para clasificación. Para ello, el algoritmo asigna una etiqueta o clase a

un nuevo punto de datos en función de la mayoría de las etiquetas de sus "k" vecinos espectralmente más cercanos. Es decir, si la mayoría de los vecinos pertenecen a una clase en particular, el nuevo punto de datos también se asigna a esa clase (Abdulridha et al., 2019). Dentro de las investigaciones generadas en el ámbito agrícola con el uso de este algoritmo destacan: la detección y clasificación de cítricos con Huanglongbing basada en reflectancia hiperespectral (Deng et al., 2019) y detección de síntomas de la mancha negra de los cítricos mediante reflectancia espectral (Xie & Lee, 2021).

2.3.5. Spectral Angle Mapper (SAM)

El algoritmo de Spectral Angle Mapper (SAM) es utilizado para la clasificación de píxeles en imágenes satelitales. El objetivo principal de SAM es asignar una etiqueta de clase a cada píxel en función de sus características espectrales. Para aplicar SAM, se comienza recopilando muestras de entrenamiento que representen cada clase de interés. Cada muestra de entrenamiento contiene información sobre los valores espectrales en las diferentes bandas de la imagen para una ubicación específica del terreno. Estas muestras deben ser representativas y abarcar la variabilidad espectral de las clases. Luego, para clasificar un píxel dado en la imagen, se calcula el ángulo entre el vector espectral del píxel y los vectores espectrales de las muestras de entrenamiento de cada clase. Cuanto más pequeño sea el ángulo, mayor será la similitud espectral entre el píxel y la clase correspondiente. Finalmente, el píxel se asigna a la clase con el ángulo espectral más pequeño, lo que indica una mayor similitud con esa clase en términos de sus propiedades espectrales (Kruse et al., 1993). Dentro de los trabajos realizados con SAM en imágenes obtenidas por sensores remotos, destacan la detección y mapeo de la cubierta vegetal (Yagoub et al., 2014) y la detección y mapeo de árboles infectados con gomosis de cítricos con datos hiperespectrales de UAV (Moriya et al., 2021).

2.4. Colección de datos y procesamiento

La recolección de imágenes se realizó utilizando un UAV multirrotor Phantom 3 Pro de DJI Innovations (SZ DJI Technology Co., Shenzhen, Guangdong, China), con un peso aproximado de 1,28 kg, con autonomía de vuelo entre 18 y 23 minutos, posicionamiento GPS/GLONASS. Los vuelos fueron planificados y automatizados utilizando aplicaciones gratuitas como Pix4Dcapture y DJI Go. El UAV se equipó con un sensor MAPIR Survey 3W fabricado

por la empresa MAPIR. Este sensor, es un equipo modificado y cuenta con tres filtros que captan información espectral de los canales RG-NIR (Red-R, Green-G, NIR Near Infrared), con una resolución de 12 megapíxeles y 12 bit de almacenamiento, con características de intervalos de captura desde 2 a 5 segundos y obturación de 1/500, además cuenta con receptor GPS externo.

Las imágenes multiespectrales del sensor MAPIR Survey 3W se recolectaron el día 9 de marzo de 2022, entre las 11 y las 13 horas. Los vuelos se realizaron a una altura de 100 m con un traslape frontal de 85% y lateral de 75%. El UAV se trasladó a una velocidad de 4 m s⁻¹, con una cobertura total de 4 ha con un tiempo de recorrido de vuelo de 18 minutos. Después de adquirir la información multiespectral, se procesaron un total de 97 imágenes en formato JPG en el software Agisoft PhotoScan (Agisoft LLC, San Petersburgo, Rusia), se realizó el flujo de proceso fotogramétrico para obtener un ortomosaico en formato Geo TIF con una resolución espacial de 5 cm píxel⁻¹ y se le aplicó una calibración de reflectancia; fue georreferenciado con 8 puntos de control terrestre obtenidos por medio de un navegador y antena Garmin Ga38 GPS/GLONASS. El ortomosaico fue proyectado al sistema de coordenadas UTM 14 N con un datum de referencia ITRF 2008-2010.

2.5. Generación de modelos

Mediante recorridos en la huerta en compañía del productor, se realizó un análisis visual sobre cada árbol para estimar el daño por enfermedades o estrés, resultando que la mayoría de los árboles tenía algún grado de daño en hojas, ramas, tronco y fruta (Figura 3). Aunque este recorrido no se realizó en temporada de cosecha, las frutas en crecimiento mostraban daños leves y severos además de la caída de las mismas.

Se realizó una clasificación supervisada sobre el ortomosaico generado del huerto. De acuerdo a los recorridos en campo y los elementos captados en el ortomosaico, las clases seleccionadas fueron: 1) árbol enfermo, 2) árbol sano, 3) suelo, 4) acolchado, 5) sombra, 6) otros y 7) otra vegetación. Se generaron 145 polígonos para la clasificación supervisada abarcando todas las clases, los cuales se distribuyeron de la siguiente manera: 30 polígonos para la clase "árbol enfermo", 30 para "árbol sano", 10 para "otra vegetación", 15 para "otros", 20 para "acolchado", 20 para "sombra" y 20 para "suelo". Los polígonos se distribuyeron por toda el área de estudio, procurando generarlos en áreas bien definidas de cada clase de acuerdo con los recorridos realizados en campo.




Figura 3. Árboles enfermos. a) Columna 16, Árbol 7 (C16A7), b) Columna 28, Árbol 15 (C28A15) y c) Columna 34, Árbol 16 (C34A16).

Los árboles con apariencia de una mejor salud se ubican en la parte suroeste de la parcela, los más enfermos en la parte norte y este. Elementos como el suelo, el acolchado y la clase "otros" se observan de manera definida en el ortomosaico. Dentro de la huerta existen otro tipo de árboles frutales (menos de 10 árboles) como mandarinos, limeros, guayabos y duraznos además de maleza, por lo que se generó la clase otra vegetación. Del total de los 145 polígonos que se generaron para la clasificación, el 70% se utilizó para entrenar los algoritmos y el 30% restante se utilizó para validar los resultados (Barman & Choudhury, 2022). Los polígonos que se utilizaron para el entrenamiento y validación fueron seleccionados de manera aleatoria. Se hicieron varios vuelos de prueba para obtener las mejores imágenes libres de sombras, procurando aprovechar cuando el sol se encontraba en el cenit.

La clasificación de los algoritmos se realizó en el software gratuito y de código abierto System for Automated Geoscientific Analyses (SAGA-GIS, Hamburgo, Alemania). Los modelos generados se convirtieron en formato Geotiff, y el manejo de los formatos se realizó en el software de Geoprocesamiento Quantum Gis, versión 2.12.1 (QGIS Development Team, Open Source Geospatial Foundation) se utilizó la proyección Universal Transversal Mercator (UTM), en la zona 14N.

2.6. Determinación del estado fitosanitario de cada árbol

La condición fitosanitaria de los árboles se determinó en campo para el entrenamiento de los algoritmos. De manera visual con el apoyo del productor se estimó únicamente el número de árboles con apariencia sana y con apariencia enferma, ya que es complicado determinar el umbral entre un árbol enfermo y uno en estrés, dando un total de 174

árboles sanos y 427 árboles enfermos. Una vez generados los modelos, se logró cuantificar el porcentaje de copa sana por árbol, de esta manera se incluyó también la condición de árbol en estrés, un punto intermedio entre árbol sano y enfermo. Algunos trabajos como el de Pino-Vargas & Huayna (2022), utilizaron índices espectrales como el NDVI, para determinar el grado de afectación por ataque de plagas en árboles frutales. De acuerdo con la experiencia del productor, un árbol de naranja se puede considerar sano cuando tres cuartas partes de la copa se encuentra en esta condición (75%), un árbol en estrés, cuando la copa sana se encuentra entre el 60 y 75% y un árbol enfermo cuando la copa sana es menor al 60%. De manera común, todos los algoritmos clasificaron píxeles diferentes a las clases "árbol sano" y "árbol enfermo" sobre la copa del árbol, por lo tanto, para la cuantificación del porcentaje de copa sana, solo se utilizaron las clases "árbol sano" y "árbol enfermo" como el total del área de la copa. Se generó una máscara digital basada en círculos vectoriales construida empleando el diámetro promedio de la copa de los árboles en la huerta (6 m), la cual se sobre puso en cada modelo para aislar un árbol de otro, con el fin de medir el daño que presenta cada árbol.

3. Resultados y discusión

Los algoritmos mostraron diferentes resultados a pesar de que todos fueron estimados con las mismas áreas de entrenamiento, en la Figura 4 se muestra el panel con el resultado de cada algoritmo. Se puede observar que los algoritmos ML (Figura 4a) y SVM (Figura 4d), presentan un mayor equilibrio entre las clases "árbol enfermo" y "árbol sano", mientras que los algoritmos que presentan mayor contraste entre sí, fueron los algoritmos kNN

(Figura 4b) que muestra casi todos los árboles enfermos y RF (Figura 4e) que muestra casi todos los árboles sanos.

El algoritmo SAM presentó una mayor confusión de píxeles en todo el modelo. La literatura muestra que este algoritmo obtiene buenos resultados cuando se usa con imágenes donde no se perciben los objetos como tal, es decir, imágenes de baja resolución espacial (Yagoub et al., 2014). En general, todos los modelos clasificaron de manera correcta la clase "suelo" y muestran resultados que coinciden con lo que se observa en campo. Para determinar el grado de precisión de cada modelo, se realizó una validación con datos independientes a los que se usaron en el entrenamiento de los modelos.

3.1. Validación de los algoritmos

Los polígonos de clasificación mostraron la tendencia de abarcar más de una clase dentro de su área en cada modelo estimado. Debido a esta situación, se optó por obtener el área de cada clase contenida dentro de cada polígono, y la clase con el área predominante fue considerada la clase estimada por los modelos para cada polígono de clasificación. En la Tabla 1, a manera de ejemplo, se muestra una parte de la evaluación que se usó para el modelo

SVM. De esta manera, también se evaluó la capacidad de todos los algoritmos para predecir de manera correcta las clases observadas en campo.

Se evaluaron de manera individual los 43 polígonos independientes elegidos para la validación de los algoritmos seleccionados. El proceso consistió en determinar la clase que predomina de acuerdo con el área que abarca cada polígono de validación al sobreponerse sobre los modelos generados de los cinco algoritmos. Se obtuvo el porcentaje de efectividad de acierto por cada clase para cada algoritmo (Tabla 2) después se obtuvo un rendimiento global para cada algoritmo al obtener el promedio de efectividad de las siete clases. También se analizó la efectividad global que tuvieron los modelos para predecir de manera correcta cada clase.

El algoritmo de ML resultó tener un mayor grado de efectividad (88,10%), teniendo un 100% de acierto en la predicción de cuatro clases incluida la clase árbol enfermo y solamente dos clases por debajo del 70% de acierto. El algoritmo RF, obtuvo la puntuación más baja (61,90%), obteniendo dos clases por debajo del 50%, incluida la clase "otros" con un 0% de efectividad, es importante recalcar que fue el único algoritmo que predijo al 100% la clase árbol sano.

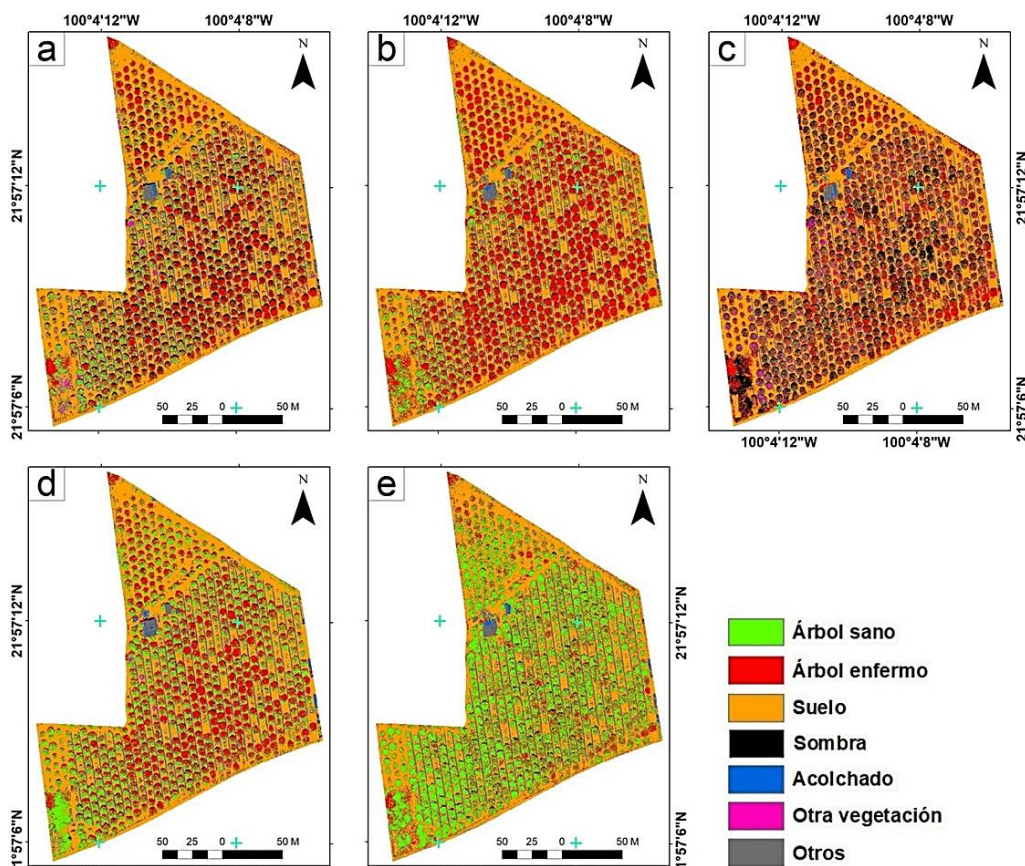


Figura 4. Clasificación supervisada de árboles en el área de estudio: a) ML, b) KNN, c) SAM, d) SVM, y e) RF.

Tabla 1

Evaluación para determinar la clase temática asignada a cada árbol individual estimada por los algoritmos

Número de polígono por clase	Clase observada en campo	Clase obtenida por el algoritmo SVM	Área	Coincidencia
2	Árbol enfermo	Otra vegetación	0,02	Sí
2		Sombra	0,06	
2		Suelo	0,03	
2		Árbol enfermo	5,29	
2		Árbol sano	1,41	
5	Árbol enfermo	Sombra	0,11	Sí
5		Árbol enfermo	7,23	
5		Árbol sano	1,72	
7	Árbol enfermo	Otra vegetación	0,04	No
7		Árbol enfermo	3,1	
7		Árbol sano	3,38	
12	Árbol enfermo	Árbol enfermo	6,35	Sí
12		Árbol sano	0,52	
14	Árbol enfermo	Sombra	0,21	Sí
14		Árbol enfermo	3,02	
14		Árbol sano	1,72	
19	Árbol enfermo	Árbol enfermo	7,74	Sí
19		Árbol sano	0,51	
21		Árbol enfermo	5,57	Sí

Tabla 2

Efectividad de los algoritmos

Clases	ML	kNN	RF	SVM	SAM	% Efectividad (clase)
Árbol sano	66,67	44,44	100,00	88,89	11,11	62,22
Árbol enfermo	100,00	100,00	33,33	77,78	88,89	80,00
Otra vegetación	100,00	75,00	50,00	75,00	100,00	80,00
Suelo	100,00	100,00	100,00	100,00	100,00	100,00
Sombra	100,00	33,33	66,67	66,67	83,33	70,00
Acolchado	83,33	100,00	83,33	33,33	83,33	76,67
Otros	66,67	0,00	0,00	100,00	66,67	46,67
Efectividad del algoritmo (%)	88,10	64,68	61,90	77,38	76,19	

El algoritmo kNN mostró un rendimiento bajo (64,68%), siendo el único algoritmo que mostró tres clases por debajo del 50% de efectividad, incluyendo la clase "otros" con un 0%. En general, los algoritmos SAM y SVM obtuvieron resultados aceptables por encima del 75% de efectividad, sin embargo, SAM obtuvo un rendimiento muy pobre en la clasificación de árboles sanos.

3.2. Determinación de la condición fitosanitaria de cada árbol

El inventario de árboles en la huerta fue de 677. Sin embargo, para la evaluación se consideraron solamente 601 árboles. Los árboles restantes se excluyeron de la evaluación debido a causas específicas, como estar secos, ser demasiado pequeños para la producción, presentar signos evidentes de enfermedad o ser de otro tipo de frutas. En **Tabla 3** se muestran los resultados de la condición fitosanitaria de cada árbol obtenida por cada modelo.

Tabla 3

Determinación de la condición de los 601 árboles evaluados

	ML	kNN	SAM	SVM	RF
Árbol sano	17	2	0	21	323
Árbol en estrés	54	20	4	124	191
Árbol enfermo	530	579	597	456	87

La evaluación se llevó a cabo de manera individual por cada árbol para los cinco algoritmos. En la **Tabla 4** se muestra como ejemplo un fragmento de la evaluación que se realizó para el algoritmo RF, calculando el porcentaje de copa sana para posteriormente ser clasificado. De acuerdo con las observaciones que se realizaron en la huerta, existen 427 árboles enfermos y 174 árboles sanos. De acuerdo con los resultados, SAM predijo el mayor porcentaje de árboles enfermos 99,33%, mientras que el porcentaje menor de árboles enfermos lo predijo RF con 14,47%; así mismo, RF predijo el mayor porcentaje de árboles sanos con 53,74% y SAM el menor con 0%. Para el caso de los árboles en estrés, RF predijo el mayor número de árboles en esta condición y SAM el menor, por lo que estos dos algoritmos son contraparte uno del otro, mostrando valores extremos a lo alto y a lo bajo, y con lo cual se exhiben como los algoritmos que tuvieron una capacidad predictiva menor para detectar la condición fitosanitaria real de la huerta. Se generó un gráfico de panel para la visualización de la condición fitosanitaria de los 601 árboles evaluados (**Figura 5**), para ello se utilizó únicamente las clases "árbol sano" y "árbol enfermo", así como

la máscara con el diámetro promedio de copa en los árboles.

Con este panel se puede vislumbrar cuáles son las zonas más afectadas en la parcela según los resultados de cada algoritmo. Confirmándose que ML y SVM, mostraron un mejor equilibrio respecto a lo observado en campo, kNN y RF con tendencias a que la mayoría de los árboles están enfermos o sanos respectivamente. Para el caso de SAM, se puede observar un alto grado de confusión por parte del algoritmo para clasificar árboles, prueba de ello es que, al retirar los píxeles de las demás clases queda un número de píxeles muy bajo para las clases "árbol sano" y "árbol enfermo", aparentando que el color de los píxeles ha sido difuminado.

3.3 Capacidad predictiva de los algoritmos

Cada algoritmo mostró fortaleza de predicción en al menos una de las clases, sin embargo, los algoritmos que mostraron un mejor desempeño para este trabajo fueron ML y SVM con un alto porcentaje de efectividad (83,3%) para predecir árboles sanos y árboles enfermos. De acuerdo con los resultados, las sombras generadas por los árboles

provocan conflicto en los algoritmos confundiendo los con vegetación enferma o generando áreas de sombra en vegetación enferma (Li et al., 2013). Otro efecto de las sombras e iluminación de las imágenes es que los píxeles de los bordes de las copas presentan diferentes valores en comparación con los píxeles del centro, lo cual genero algunos errores de clasificación (Figura 4), Kumar et al. (2012) también reportaron este efecto en su investigación. Las estadísticas muestran que el algoritmo ML fue el que mejor interpretó las sombras con una efectividad del 100% (Tabla 2).

Aunque kNN y RF obtuvieron rendimientos bajos, fueron capaces de predecir al 100% árboles enfermos (kNN) y árboles sanos (RF) (Tabla 2). Sin embargo, esto no significa que sean buenos predictores para este trabajo, ya que por un lado kNN mostró una tendencia a la clasificación de árboles enfermos en todo el mosaico y RF una tendencia a clasificar todos los árboles como sanos. Como consecuencia tuvieron un rendimiento muy bajo al clasificar la contraparte de árboles sanos y enfermos. Su bajo rendimiento se observó al revisar que las clasificaciones predecían de manera marginal, las demás clases temáticas.

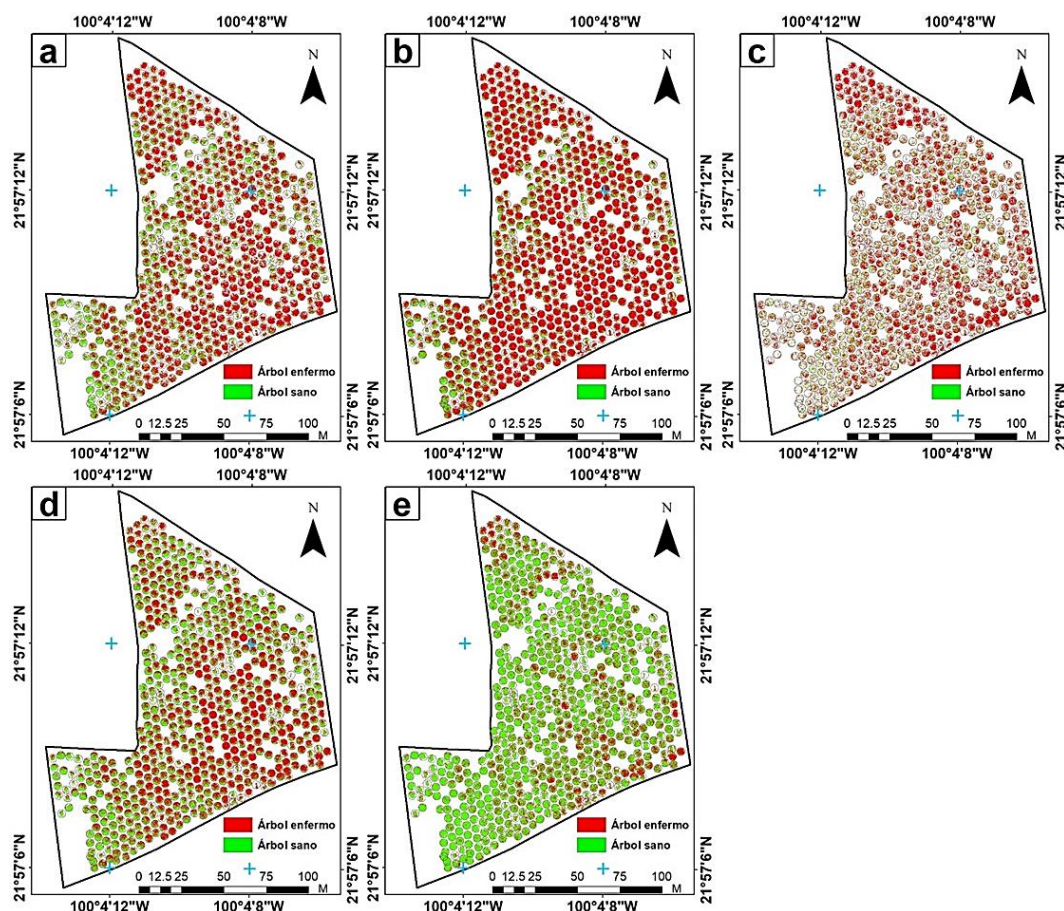


Figura 5. Condición fitosanitaria estimada por los algoritmos: a) ML, b) kNN, c) SAM, d) SVM, y e) RF.

Existen pocos estudios que comparan el rendimiento de diferentes métodos de aprendizaje automático para detectar enfermedades en cítricos, sin embargo, se ha observado que los diferentes métodos presentan tendencias de preferencia de clasificación hacia árboles sanos o enfermos aun siendo entrenados con las mismas muestras y condiciones (Lan et al., 2020).

La evaluación de los algoritmos se puede abordar mediante dos enfoques: 1) la efectividad global de la clasificación y 2) la efectividad del algoritmo por clase temática. Para el caso de la efectividad global, ML, SVM y SAM fueron los algoritmos más capaces de clasificar mejor los píxeles de la imagen. Mientras que, respecto a cada clase temática, para el caso de la clase árbol sano, RF (100%) y SVM (88,89%) fueron los algoritmos con un mejor desempeño. Para el caso de la clase árbol enfermo, ML (100%), kNN (100%) y SAM (88,89%) fueron los algoritmos que mejor trabajaron. Para el caso de la clase suelo, todos los algoritmos (ML, kNN, RF, SVM y SAM) presentaron una efectividad del 100% (Tabla 2).

3.4 Comparación de la efectividad de los algoritmos contra otras investigaciones

En general, la precisión de la clasificación para los diferentes métodos puede variar de acuerdo con el tipo de imágenes utilizadas, los sensores utilizados, las técnicas de obtención de las imágenes, las condiciones climáticas durante la adquisición de datos, técnicas adicionales para mejorar la clasificación y los métodos de validación. En este caso se obtuvieron resultados favorables para algunos métodos, como ML y SVM, en el análisis global. Sin embargo, en otras investigaciones similares, la precisión de SVM fue baja (65%) (Lan et al., 2020). Además, los resultados para kNN (55%) fueron comparables con los obtenidos en esta investigación (65%), aunque

Barman & Choudhury (2022) lograron una precisión mucho más alta para kNN (90%). El método SAM mantuvo resultados consistentes en la clasificación general para predecir enfermedades en los cítricos, con una precisión del 76% en este estudio. Moriya et al. (2021) reportaron una precisión del 79% para detectar gomosis de los cítricos, mientras que Li et al. (2013) obtuvieron un 86% y Kumar et al. (2012) un 87%, ambos para la detección de HLB. En general, los resultados indican que ML y SVM se destacan en algunos casos, pero también pueden tener limitaciones en diferentes contextos de investigación. Por otro lado, el método SAM muestra resultados interesantes en la clasificación de enfermedades en cítricos, con niveles aceptables de precisión. Los hallazgos de esta investigación se suman a la creciente literatura sobre el uso de técnicas de análisis para el diagnóstico de enfermedades en cítricos y pueden tener implicaciones importantes para la mejora de las estrategias de manejo y control de estas enfermedades.

3.5 Técnicas de validación usadas en trabajos similares

Las técnicas de validación ayudan a mejorar notablemente la precisión de los resultados. Para este trabajo se utilizó el 30% de la muestra de los polígonos generados. Por otro lado, Kumar et al. (2012) utilizaron pruebas de reacción en cadena de la polimerasa (PCR) para detectar árboles infectados con HLB lo cual mejoró notablemente la precisión de sus resultados. Sus resultados de precisión para cada clase temática también fueron variables, el suelo fue la clase que mejor se clasificó ya que todos los algoritmos obtuvieron una precisión del 100%, posiblemente porque fue la clase más uniforme en cuanto a la reflectancia de sus píxeles.

Tabla 4
Fragmento de la evaluación de la condición fitosanitaria para cada árbol

Clave Árbol	Área copa sana	Área copa enferma	Área total	Porcentaje de copa sana	Condición estimada por el algoritmo RF
C33A9	24,98	7,62	32,59	76,63	Árbol sano
C33A10	16,24	7,01	23,25	69,83	Árbol en estrés
C33A11	16,22	8,83	25,05	64,74	Árbol en estrés
C33A12	13,15	7,41	20,56	63,97	Árbol en estrés
C33A13	17,74	12,44	30,18	58,79	Árbol enfermo
C33A14	9,42	7,65	17,07	55,20	Árbol enfermo
C33A15	20,32	5,08	25,40	79,99	Árbol sano
C33A17	12,21	4,70	16,91	72,21	Árbol en estrés
C34A7	13,81	18,40	32,22	42,88	Árbol enfermo
C34A8	24,28	3,48	27,76	87,48	Árbol sano
C34A9	18,96	8,34	27,30	69,44	Árbol en estrés
C34A10	12,67	2,87	15,54	81,51	Árbol sano
C34A11	16,39	4,26	20,65	79,36	Árbol sano
C34A12	14,81	4,15	18,96	78,12	Árbol sano
C34A14	18,49	6,47	24,96	74,09	Árbol en estrés

En lo que respecta a la clasificación de árboles sanos y enfermos, **Lan et al. (2020)** y **Barman & Choudhury (2022)** mencionan que los algoritmos tienden a tener preferencias de clasificación tanto para árboles sanos o árboles enfermos; de acuerdo con sus resultados, los algoritmos tendieron a clasificar mejor los árboles sanos, mientras que para esta investigación la tendencia general de los algoritmos fue a clasificar árboles enfermos.

Algunos investigadores se han apoyado de técnicas para centrarse únicamente en los árboles de las parcelas, ignorando los demás elementos presentes, **Li et al. (2013)** utilizaron el método de SVM para extraer únicamente la clase árbol y evitar el ruido de las demás clases presentes. En nuestra investigación decidimos trabajar con todas las clases presentes en la parcela pensando en que en un futuro estas técnicas se pueden automatizar y no depender de más métodos para generar la clasificación de las imágenes. La mayoría de los algoritmos mostraron una tendencia a predecir un mayor número de árboles enfermos, esta tendencia corresponde a la realidad de la parcela en los últimos cinco años, ya que el productor reporta que en el 2016 cosechó 130 toneladas de naranja, mientras que para 2021 la cosecha alcanzó solo 35 toneladas, teniendo una pérdida de más del 70% en cinco años.

3.6 Importancia del monitoreo de árboles con métodos no destructivos

Los datos del Servicio de Información Agroalimentaria y Pesquera (**SAGARPA, 2021**), muestran que, en el 2020 en la región de Rioverde se sembró un 17,2% (5666 ha), se cosechó un 16,13% (5186 ha) y se obtuvo una producción del 32,53% (121351 t) del total estatal. Si bien se puede observar que la producción es alta con relación al resto del estado. La gran relevancia de esta fruta para la región es el valor de la producción ya que ocupó el 63,5 del valor total de la producción estatal. Además, la producción de la región representa el 2,73% de la producción nacional y 5,78% el valor total de la producción nacional. En el 2021, la participación dentro del Estado en cuanto a área sembrada y cosechada, así como la producción se mantuvo prácticamente igual, sin embargo, la participación en el valor de la producción total disminuyó a 44,4%, y a nivel nacional disminuyó a 3,58% lo cual indica una pérdida del valor de la naranja de la región de Rioverde.

El monitoreo de la copa de los árboles para determinar la salud se puede ver influenciado por la época del año. Debido a esto los modelos generados son dinámicos a lo largo del año y es difícil

generar un modelo que se adapte a cada periodo de crecimiento (**Lan et al., 2020**). La idea de hacer la toma de imágenes en época de seca (marzo), fue evitar el efecto de la temporada de lluvia en el verdor del follaje, y como una causa potencial de generación de una mayor cantidad de árboles sanos, lo que representaría un sesgo en las evidencias. Normalmente, los trabajos realizados para clasificación de tipos de vegetación recomiendan el uso de imágenes en época de sequía para tener un mayor contraste espectral entre las diferentes coberturas y tipos de vegetación, en este caso niveles de salud de la copa o grados de estrés.

Los resultados obtenidos en este trabajo son prometedores. Como investigación futura se plantea, analizar el efecto del tamaño de muestra en el algoritmo kNN sobre el resultado de las estimaciones, y de esta manera explorar la posibilidad de manejar tamaños de muestra estándar para todas las clases. También, se plantea la exploración de otro tipo de algoritmos, como aquellos basados en redes neuronales, o deep learning, para mejorar el potencial predictivo de los modelos. Sin duda, este trabajo permitirá ser una valiosa herramienta de manejo de la huerta y de esta manera poder mejorar la condición de salud de los árboles, y por ende incrementar la producción.

4. Conclusiones

En este trabajo se desarrolló una metodología para la identificación de árboles de naranja enfermos en un huerto localizado en la región del cinturón cítrico de México, Rioverde, San Luis Potosí. Se concluye que ML y SVM fueron los algoritmos que tuvieron un mejor desempeño para la clasificación de árboles sanos y árboles enfermos en un ortomosaico compuesto por imágenes multiespectrales. Se logró obtener un inventario de árboles de naranja de manera precisa, así como diagnosticar la salud de cada árbol de manera individual dentro de la huerta. El monitoreo de árboles individuales dentro de huertas de frutales empleando datos multiespectrales demostró ser una poderosa herramienta para lograr un manejo agrícola de precisión para optimizar el uso de insumos e incrementar el rendimiento de producción.

Agradecimientos

Este trabajo forma parte de la tesis del primer autor, quien agradece al CONAHCYT de México la beca No. 713302 otorgada para la realización de los estudios doctorales. Se agradece a dos revisores anónimos cuyos comentarios enriquecieron enormemente la presentación de esta investigación.

Conflictos de Interés

Los autores declaran no tener conflictos de interés.

ORCID

- J. C. Díaz-Rivera  <https://orcid.org/0009-0000-0062-3935>
 C. A. Aguirre-Salado  <https://orcid.org/0000-0003-3422-7193>
 C. Loredó-Ostí  <https://orcid.org/0000-0001-5221-2660>
 M. Escoto-Rodríguez  <https://orcid.org/0000-0002-0812-4484>

Referencias bibliográficas

- Abdulridha, J., Batuman, O., & Ampatzidis, Y. (2019). UAV-Based Remote Sensing Technique to Detect Citrus Canker Disease Utilizing Hyperspectral Imaging and Machine Learning. *Remote Sensing*, 11(11), 1373. <https://doi.org/10.3390/rs11111373>
- Ali, H., Lali, M. I., Nawaz, M. Z., Sharif, M., & Saleem, B. A. (2017). Symptom based automated detection of citrus diseases using color histogram and textural descriptors. *Computers and Electronics in Agriculture*, 138, 92-104. <https://doi.org/10.1016/j.compag.2017.04.008>
- Alzubi, E., Shbikat, N., & Noche, B. (2023). A system dynamics model to improving sustainable performance of the citrus farmers in Jordan Valley. *Cleaner Production Letters*, 4, 100034. <https://doi.org/10.1016/j.clpl.2023.100034>
- Ampatzidis, Y., Partel, V., & Costa, L. (2020). Agroview: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 174, 105457. <https://doi.org/10.1016/j.compag.2020.105457>
- Antolínez, C.A., Olarte-Castillo, X.A., Martini, X., & Rivera, M.J. (2022). Influence of daily temperature maximums on the development and short-distance movement of the Asian citrus psyllid. *Journal of Thermal Biology*, 110, 103354. <https://doi.org/10.1016/j.jtherbio.2022.103354>
- Atta, S., Zhou, C., Zhou, Y., Cao, M., & Wang, X. (2012). Distribution and Research Advances of Citrus tristeza virus. *Journal of Integrative Agriculture*, 11(3), 346-358. [https://doi.org/10.1016/S2095-3119\(12\)60019-7](https://doi.org/10.1016/S2095-3119(12)60019-7)
- Balfagón, D., Arbona, V., & Gómez-Cadenas, A. (2021). El futuro de los cítricos: Impacto del cambio climático en la citricultura. *Metode Science Studies Journal*, 110, 61-67. <https://doi.org/10.7203/metode.12.20319>
- Barman, U., & Choudhury, R. D. (2022). Smartphone assist deep neural network to detect the citrus diseases in Agri-informatics. *Global Transitions Proceedings*, 3(2), 392-398. <https://doi.org/10.1016/j.gltp.2021.10.004>
- Bassanezi, R. B., Primiano, I. V., & Vescove, H. V. (2021). Effect of enhanced nutritional programs and exogenous auxin spraying on huanglongbing severity, fruit drop, yield and economic profitability of orange orchards. *Crop Protection*, 145, 105609. <https://doi.org/10.1016/j.cropro.2021.105609>
- Berk, Z. (2016). Chapter 5 - Diseases and pests. *Citrus Fruit Processing*, 83-93. <https://doi.org/10.1016/B978-0-12-803133-9.00005-9>
- Braham, M., Boulahia-Kheder, S., Kahia, M., & Noura, S. (2023). Aphids and citrus responses to nitrogen fertilization. *Journal of the Saudi Society of Agricultural Sciences*, S1658077X23000322. <https://doi.org/10.1016/j.jssas.2023.03.003>
- Calou, V. B. C., Teixeira, A. D. S., Moreira, L. C. J., Lima, C. S., De Oliveira, J. B., & De Oliveira, M. R. R. (2020). The use of UAVs in monitoring yellow sigatoka in banana. *Biosystems Engineering*, 193, 115-125. <https://doi.org/10.1016/j.biosystemseng.2020.02.016>
- Chang, A., Yeom, J., Jung, J., & Landivar, J. (2020). Comparison of Canopy Shape and Vegetation Indices of Citrus Trees Derived from UAV Multispectral Images for Characterization of Citrus Greening Disease. *Remote Sensing*, 12(24), 4122. <https://doi.org/10.3390/rs12244122>
- Deng, X., Huang, Z., Zheng, Z., Lan, Y., & Dai, F. (2019). Field detection and classification of citrus Huanglongbing based on hyperspectral reflectance. *Computers and Electronics in Agriculture*, 167, 105006. <https://doi.org/10.1016/j.compag.2019.105006>
- El Imanni, H. S., El Harti, A., El Mostafa, B., Mouncif, H., Eddassouqui, F., Achraf Hasnai, M., & Ismail Zinelabidine, M. (2023). Multispectral UAV data for detection of weeds in a citrus farm using machine learning and Google Earth Engine: Case study of Morocco. *Remote Sensing Applications: Society and Environment*, 30, 100941. <https://doi.org/10.1016/j.rsase.2023.100941>
- Estrada-Zúñiga, A. C., Cárdenas, J., Víctor Bejar, J., & Ñaupari, J. (2022). Biomass estimation of a high Andean plant community with multispectral images acquired using UAV remote sensing and Multiple Linear Regression, Support Vector Machine and Random Forests models. *Scientia Agropecuaria*, 13(3), 301-310. <https://doi.org/10.17268/sci.agropecu.2022.027>
- Ezrari, S., Radouane, N., Thiri, A., El Housni, Z., Mokriani, F., et al. (2022). Dry root rot disease, an emerging threat to citrus industry worldwide under climate change: A review. *Physiological and Molecular Plant Pathology*, 117, 101753. <https://doi.org/10.1016/j.pmp.2021.101753>
- Freitas, T. A., Proença, C. A., Baldo, T. A., Materón, E. M., Wong, A., Magnani, R. F., & Faria, C. F. (2019). Ultrasensitive immunoassay for detection of Citrus tristeza virus in citrus sample using disposable microfluidic electrochemical device. *Talanta*, 205, 120110. <https://doi.org/10.1016/j.talanta.2019.07.005>
- García-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*, 91, 106-115. <https://doi.org/10.1016/j.compag.2012.12.002>
- Godefroid, M., (2023). Species distribution models predicting climate suitability for the psyllid *Trioza erytrae*, vector of citrus greening disease. *Crop Protection*, 168: 106228. <https://doi.org/10.1016/j.cropro.2023.106228>
- Hajeri, S., & Yokomi, R. (2023). Chapter 6 - Citrus tristeza virus. *Plant RNA viruses*, 117-133. <https://doi.org/10.1016/B978-0-323-95339-9.00009-0>
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749. <https://doi.org/10.1080/01431160110040323>
- Kruse, F. A., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., & Goetz, A. F. H. (1993). The Spectral Image Processing System (SIPS) Interactive Visualization and Analysis of Imaging Spectrometer Data. *Remote Sensing of Environment*, 44, 145-163. [https://doi.org/10.1016/0034-4257\(93\)90013-N](https://doi.org/10.1016/0034-4257(93)90013-N)
- Kumar, A., Lee, W. S., Ehsani, R. J., Albrigo, L. G., Yang, C., & Mangan, R. L. (2012). Citrus greening disease detection using aerial hyperspectral and multispectral imaging techniques. *Journal of Applied Remote Sensing*, 6, 063542. <https://doi.org/10.1117/1.JRS.6.063542>
- Lan, Y., Huang, Z., Deng, X., Zhu, Z., Huang, H., et al. (2020). Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Computers and Electronics in Agriculture*, 171, 105234. <https://doi.org/10.1016/j.compag.2020.105234>
- Li, H., Lee, W. S., Wang, K., Ehsani, R., & Yang, C. (2013). Extended spectral angle mapping (ESAM) for citrus greening disease detection using airborne hyperspectral imaging. *Precision Agriculture*, 15(2). <https://doi.org/10.1007/s11119-013-9325-6>
- Milind, L. (2023). Chapter 23 - World fresh citrus trade and quarantine issues. *Citrus Fruit (second Edition)*. Biology, Technology and Evaluation, 737-761. <https://doi.org/10.1016/B978-0-323-99306-7.00017-7>
- Moriya, É. A. S., Imai, N. N., Tommaselli, A. M. G., Berveglieri, A., Santos, G. H., Soares, M. A., Marino, M., & Reis, T. T. (2021). Detection and mapping of trees infected with citrus gummosis using UAV hyperspectral data. *Computers and*

- Electronics in Agriculture*, 188, 106298. <https://doi.org/10.1016/j.compag.2021.106298>
- Moussaid, A., El Fkihi, S., & Zennay, Y. (2020). Citrus orchards monitoring based on remote sensing and artificial intelligence techniques: A review of the literature. *Science and In Proceedings of the 2nd International Conference on Advanced Technologies for Humanity - ICATH*, 1, 172-178. <https://doi.org/10.5220/0010432001720178>
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222. <https://doi.org/10.1080/01431160412331269698>
- Pino-Vargas, E. M., & Huayna, G. (2022). Spatial and temporal evolution of olive cultivation due to pest attack, using remote sensing and satellite image processing. *Scientia Agropecuaria*, 13(2), 149-157. <https://doi.org/10.17268/sci.agropecu.2022.013>
- Rozenberg, G., Kent, R., & Blank, L. (2021). Consumer-grade UAV utilized for detecting and analyzing late-season weed spatial distribution patterns in commercial onion fields. *Precision Agriculture*, 22, 1317-1332. <https://doi.org/10.1007/s11119-021-09786-y>
- Scheeres, J., De Jong, J., Brede, B., Brancalion, P. H. S., Broadbent, E. N., et al. (2023). Distinguishing forest types in restored tropical landscapes with UAV-borne LIDAR. *Remote Sensing of Environment*, 290, 113533. <https://doi.org/10.1016/j.rse.2023.113533>
- Shao, G., Han, W., Zhang, H., Liu, S., Wang, Y., Zhang, L., & Cui, X. (2021). Mapping maize crop coefficient Kc using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices. *Agricultural Water Management*, 252, 106906. <https://doi.org/10.1016/j.agwat.2021.106906>
- SAGARPA (2021). Sistema de Información Agroalimentaria de Consulta (SIACON). *Servicio de Información Agroalimentaria y Pesquera* (SIAP). <https://www.gob.mx/siap/documentos/siacon-ng-161430>. Consulta 3 de abril de 2023
- Spreen, T. H., Gao, Z., Fernandes, W., & Zansler, M. L. (2020). Global economics and marketing of citrus products. *The Genus Citrus*, 471-493. <https://doi.org/10.1016/b978-0-12-812163-4.00023-1>
- Sun, J., Yang, J., Zhang, C., Yun, W., & Qu, J. (2013). Automatic remotely sensed image classification in a grid environment based on the maximum likelihood method. *Mathematical and Computer Modelling*, 58(3-4), 573-581. <https://doi.org/10.1016/j.mcm.2011.10.063>
- Tuwo, M., Kuswinanti, T., Nasruddin, A. & Tambaru, E. 2024. Uncovering the presence of CVPD disease in citrus varieties of South Sulawesi, Indonesia: A molecular approach. *Journal of Genetic Engineering and Biotechnology*, 22, 100332. <https://doi.org/10.1016/j.jgeb.2023.100332>
- Xie, C., & Lee, W. S. (2021). Detection of citrus black spot symptoms using spectral reflectance. *Postharvest Biology and Technology*, 180, 111627. <https://doi.org/10.1016/j.postharvbio.2021.111627>
- Xu, C., Alhejaili, W., Saifullah, S., Khan, A., Khan, J., & El-Shorbagy, M.A. (2022). Analysis of Huanglongbing disease model with a novel fractional piecewise approach. *Chaos, Solitons & Fractals*, 161, 112316. <https://doi.org/10.1016/j.chaos.2022.112316>
- Yagoub, H., Belbachir, A. H., & Benabadji, N. (2014). Detection and mapping vegetation cover based on the Spectral Angle Mapper algorithm using NOAA AVHRR data. *Advances in Space Research*, 53(12), 1686-1693. <https://doi.org/10.1016/j.asr.2014.03.020>
- Zabihi, H., Vogeler, L., Amin, Z. M., & Gourabi, B. R. (2016). Mapping the sensitivity of citrus crops to freeze stress using a geographical information system in Ramsar, Iran. *Weather and Climate Extremes*, 14, 17-23. <https://doi.org/10.1016/j.wace.2016.10.002>