



UNIVERSIDAD AUTÓNOMA DE SAN LUIS POTOSÍ  
FACULTAD DE AGRONOMÍA Y VETERINARIA  
CENTRO DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO



**DELIMITACIÓN DE ZONAS DE MANEJO AGRÍCOLA  
DEL CULTIVO DE NARANJA (*Citrus sinensis* L. Osbeck) EMPLEANDO  
TÉCNICAS DE PERCEPCIÓN REMOTA Y  
SISTEMAS DE INFORMACIÓN GEOGRÁFICA**

**Por:**

**M.T.G.A. Juan Carlos Díaz Rivera**

**Tesis presentada como requisito parcial para obtener el grado de**

**Doctor en Ciencias Agropecuarias**

Febrero, 2024



UNIVERSIDAD AUTÓNOMA DE SAN LUIS POTOSÍ  
FACULTAD DE AGRONOMÍA Y VETERINARIA  
CENTRO DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO



**DELIMITACIÓN DE ZONAS DE MANEJO AGRÍCOLA  
DEL CULTIVO DE NARANJA (*Citrus sinensis* L. Osbeck) EMPLEANDO  
TÉCNICAS DE PERCEPCIÓN REMOTA Y  
SISTEMAS DE INFORMACIÓN GEOGRÁFICA**

**Por:**

**M.T.G.A. Juan Carlos Díaz Rivera**

**Tesis presentada como requisito parcial para obtener el grado de  
Doctor en Ciencias Agropecuarias**

**Comité**

Director: Dr. Carlos Arturo Aguirre-Salado

Asesora: Dra. Liliana Miranda-Aragón

Asesor: Dr. Martín Escoto-Rodríguez

Asesora: Dra. Catarina Loredó-Osti

Asesor externo: Dr. Hilario Charcas-Salazar

Febrero, 2024

La presente tesis titulada "Delimitación de zonas de manejo agrícola del cultivo de naranja (*Citrus sinensis* l. Osbeck) empleando técnicas de percepción remota y sistemas de información geográfica" realizada por Juan Carlos Díaz Rivera, como requisito parcial para obtener el grado de Doctor en Ciencias Agropecuarias, fue revisada y aprobada por el siguiente Comité de Tesis.

Dr. Carlos Arturo Aguirre-Salado

Director

---

Dra. Liliana Miranda-Aragón

Asesora

---

Dr. Martín Escoto-Rodríguez

Asesor

---

Dra. Catarina Loredo-Osti

Asesora


---

Dr. Hilario Charcas-Salazar

Asesor externo

---

A los doce días del mes de febrero de 2024.



DELIMITACIÓN DE ZONAS DE MANEJO AGRÍCOLA DEL CULTIVO DE  
NARANJA (*Citrus sinensis* L. Osbeck) EMPLEANDO TÉCNICAS DE  
PERCEPCIÓN REMOTA Y SISTEMAS DE INFORMACIÓN GEOGRÁFICA ©  
2024 Por Juan Carlos Díaz-Rivera Licencia bajo CC BY-NC-ND 4.0

## CONTENIDO

	Página
AGRADECIMIENTOS.....	iii
CONTENIDO.....	vii
ÍNDICE DE CUADROS.....	xi
ÍNDICE DE FIGURAS.....	xiii
RESUMEN.....	xv
SUMMARY.....	xvii
CAPÍTULO 1. INTRODUCCIÓN GENERAL.....	1
Hipótesis.....	6
Objetivos.....	6
LITERATURA CITADA.....	7
CAPÍTULO 2. LAS ZONAS DE MANEJO, LA INNOVADORA TÉCNICA QUE PROMETE MEJORAR LA PRODUCCIÓN DE CÍTRICOS.....	11
RESUMEN.....	11
ABSTRACT.....	11
INTRODUCCIÓN.....	12
Amenazas y Riesgos Para la Sostenibilidad de los Cítricos.....	13
Plagas y enfermedades, amenazas directas.....	13
El cambio climático y su influencia en la producción de cítricos.....	14
Producción Global de Naranja, Tendencias, Factores Influyentes y Proyecciones Futuras.....	15
Métodos de Manejo Utilizados en Huertas de Naranjas con la Presencia de Enfermedades y Bajo Rendimiento de los Cítricos.....	19
Influencia de la teledetección en la agricultura.....	19
Concepto y aplicación de la agricultura de precisión.....	21
Otros métodos utilizados.....	25
Definición y Aplicación de las Zonas de Manejo Agrícola.....	27
Abandono de Huertos: una Problemática Latente.....	30

CONCLUSIONES.....	31
LITERATURA CITADA.....	31
CAPÍTULO 3. GENERACIÓN DE ZONAS DE MANEJO A PARTIR DEL NDVI, PRODUCCIÓN Y CALIDAD DE LA FRUTA EN ÁRBOLES DE CÍTRICOS EN UNA HUERTA DE LA REGIÓN CENTRO DE MÉXICO.....	39
RESUMEN.....	39
ABSTRACT.....	40
INTRODUCCIÓN.....	40
MATERIALES Y MÉTODOS.....	42
Área de Estudio.....	42
Inventario de Árboles.....	42
Selección de Árboles Para el Muestreo.....	43
Variables medidas.....	45
Adquisición de datos de muy alta resolución espacial.....	49
Metodología Usada Para la Generación de las Zonas de Manejo.....	50
Generación de Índices de Vegetación (NDVI).....	53
RESULTADOS.....	54
Mapas de Calidad y Producción de Naranja.....	54
Delimitación de Zonas de Manejo.....	56
Relación del NDVI con la Calidad en las Zonas de Manejo.....	59
DISCUSIÓN.....	61
Características Ideales Para la Naranja en la Región Productora.....	61
Determinación del Número de Zonas de Manejo.....	61
Relación del NDVI con la Calidad y Producción.....	62
Factores Externos que Influyen en la Producción.....	63
Nutrición y Calidad del Suelo.....	64
CONCLUSIONES.....	65
LITERATURA CITADA.....	66
CAPÍTULO 4. CLASIFICACIÓN DE ÁRBOLES ENFERMOS EN UNA HUERTA DE NARANJA MEDIANTE APRENDIZAJE AUTOMÁTICO E IMÁGENES DE MUY ALTA RESOLUCIÓN ESPACIAL.....	71

RESUMEN.....	71
ABSTRACT.....	72
INTRODUCCIÓN.....	72
MATERIALES Y MÉTODOS.....	74
Área de Estudio.....	74
Descripción de la Metodología.....	75
Algoritmos Empleados.....	76
Maximum Likelihood (ML).....	76
Random Forest (RF).....	77
Support Vector Machine (SVM).....	77
k-Nearest Neighbor (kNN).....	78
Spectral Angle Mapper (SAM).....	78
Colección de Datos y Procesamiento.....	79
Generación de Modelos.....	80
Determinación del Estado Fitosanitario de Cada Árbol.....	81
RESULTADOS.....	82
Validación de Algoritmos.....	83
Determinación la Condición Fitosanitaria de Cada Árbol.....	86
DISCUSIÓN.....	89
CONCLUSIONES.....	92
LITERATURA CITADA.....	93
CAPÍTULO 5. IMPACTO DE LA PRECIPITACIÓN SOBRE LA APTITUD DEL SUELO PARA EL CULTIVO DE NARANJA EN UNA REGIÓN SEMIÁRIDA DE MÉXICO.....	98
RESUMEN.....	98
ABSTRACT.....	99
INTRODUCCIÓN.....	99
MATERIALES Y MÉTODOS.....	102
Área de Estudio.....	102
Datos Utilizados.....	104
Criterios de Estandarización.....	107

Proceso de Jerarquía Analítica .....	113
Combinación Lineal Ponderada.....	116
Análisis de Componentes Principales para Determinar la Aptitud del Suelo Durante Varios Años.....	117
Aptitud Estimada del Suelo vs Distribución Espacial Actual de los Naranjos .....	118
RESULTADOS.....	120
Variación Espaciotemporal de la Precipitación.....	120
Patrón Espacial de Aptitud Anual del Suelo Para el Cultivo de Naranjos....	120
Análisis de Componentes Principales.....	123
Aptitud Integrada del Suelo Para el Cultivo de Naranjos.....	126
Comparación de Mapas de Aptitud del Suelo vs Distribución Espacial de Naranjos.....	128
DISCUSIÓN.....	130
Variación Espaciotemporal de la Precipitación .....	130
Patrón Espacial de Aptitud Anual del Suelo Para el Cultivo de Naranjos....	131
Aptitud del Suelo Integrada Para el Cultivo de Naranjos.....	132
Validación de los Resultados.....	133
CONCLUSIONES.....	135
LITERATURA CITADA.....	136
CAPÍTULO 6. DISCUSIÓN Y CONSIDERACIONES FINALES.....	145
LITERATURA CITADA.....	151
ANEXOS.....	152



## ÍNDICE DE CUADROS

Cuadro	CAPÍTULO 2	Página
1	Comparación de sensores remotos.....	20
<b>CAPÍTULO 3</b>		
1	Valores del NDVI general promedio y NDVI promedio calculado con valores mayores de 0.3.....	59
<b>CAPÍTULO 4</b>		
1	Evaluación para determinar la clase temática asignada a cada árbol individual estimada por los algoritmos.....	84
2	Efectividad de los algoritmos.....	85
3	Determinación de la condición de los 601 árboles evaluados.....	86
4	Fragmento de la evaluación de la condición fitosanitaria para cada árbol.....	87
<b>CAPÍTULO 5</b>		
1	Valores de estandarización para subcriterios y valores de ponderación asignados.....	111
2	Matrices de comparación por pares dentro de criterios.....	114
3	Matrices de comparación por pares entre criterios.....	115
4	Ponderación de criterios y subcriterios.....	115
5	Ecuaciones utilizadas para determinar la aptitud del suelo mediante subcriterios para el cultivo de naranjos en Rioverde, México.....	116
6	Ecuación utilizada para determinar la aptitud final del suelo para el cultivo de naranja en Rioverde, México.....	117
7	Matriz de valores propios, vectores propios y varianza explicada obtenida del análisis de componentes principales ejecutado para	

	integrar los valores anuales de la aptitud del suelo en un mapa de aptitud del suelo homogéneo basado en PCA, es decir, mapa PC1....	124
8	Matriz de cargas para componentes principales.....	125
9	Aptitud estimada del suelo para huertos de naranjos en Rioverde, México.....	127
10	Comparación regional de la ubicación actual de los huertos de naranjos con la aptitud estimada del suelo en Rioverde, México.....	129

## ÍNDICE DE FIGURAS

Figura	CAPÍTULO 2	Página
1	Producción mundial de naranja, 2010-2022. Gráfica construida a partir de datos obtenidos de Statista. Fuente: <a href="https://acortar.link/ylhTVD">https://acortar.link/ylhTVD</a> , <a href="https://acortar.link/pQ4u4V">https://acortar.link/pQ4u4V</a> .....	16
2	Principales países productores de naranja en el mundo en los últimos 9 años. *En el 2019 México sale del top 5, reingresa al siguiente año, **En el 2022, Estados Unidos sale del top 5. Gráfica construida a partir de datos obtenidos de United States Department of Agriculture, disponible en <a href="https://acortar.link/UiBQcl">https://acortar.link/UiBQcl</a> .....	17
<b>CAPÍTULO 3</b>		
1	Ubicación del área de estudio.....	43
2	Inventario de árboles seleccionados para el muestreo.....	44
3	Etiquetado de árbol en campo.....	45
4	Panel de mapas de calidad de la fruta: a) diámetro, b) grosor de la cáscara, c) peso individual, d) semillas por naranja, e) sabor y f) producción.....	55
5	Zonas de calidad de la fruta para cada variable: a) diámetro, b) grosor de la cáscara, c) peso individual, d) semillas, e) sabor y f) producción.....	57
6	a) Mapa general de zonas de calidad de la fruta y b) Capa de zonas calidad de la fruta montado sobre la huerta de estudio.....	58
7	Reclasificación del inventario general de la huerta con los valores de NDVI promedio mayores a 0.3 obtenido con el sensor MAPIR..	60
<b>CAPÍTULO 4</b>		
1	a) Área de estudio e inventario de árboles. b) Acercamiento para visualizar la clave de identificación de árbol.....	75
2	Diagrama de flujo de la metodología.....	76

3	Árboles enfermos. a) Columna 16, Árbol 7 (C16A7), b) Columna 28, Árbol 15 (C28A15) y c) Columna 34, Árbol 16 (C34A16).....	80
4	Clasificación supervisada de árboles en el área de estudio: a) ML, b) kNN, c) SAM, d) SVM, y e) RF.....	83
5	Condición fitosanitaria estimada por los algoritmos: a) ML, b) kNN, c) SAM, d) SVM, y e) RF.....	88

## CAPÍTULO 5

1	Localización del área de estudio.....	103
2	VARIABLES UTILIZADAS EN EL ANÁLISIS.....	106
3	Diagrama de flujo utilizado en la metodología.....	119
4	Distribución espaciotemporal de la precipitación anual basada en sensores remotos construida con datos diarios del NDVI en el área de estudio.....	121
5	Aptitud del suelo para huertos de naranjos estimada mediante el uso de precipitación anual basada en sensores remotos para cada año: 2000-2019.....	122
6	Aptitud del suelo estimada utilizando la precipitación media anual obtenida a partir de la interpolación de datos puntuales de estaciones meteorológicas.....	127
7	Aptitud del suelo estimada reuniendo 20 años de datos de aptitud con análisis de componentes principales.....	128
8	Zoom aplicado a los huertos de cítricos cultivados para validar la aptitud del suelo: aptitud del suelo basado en MAP (izquierda) y aptitud del suelo basado en PCA (derecha).....	129

## RESUMEN

Las herramientas geoespaciales y los productos de percepción remota a diversas escalas espaciales y temporales aplicados en la agricultura de precisión, juegan un papel fundamental para garantizar la sostenibilidad de la producción agrícola. Los cítricos son frutos de alto valor comercial por sus amplios beneficios a la salud humana, no obstante, actualmente las plagas, enfermedades y el cambio climático están comprometiendo su producción global, y por ende, el abastecimiento para satisfacer su demanda. Principalmente en la región de Rioverde, San Luis Potosí, perteneciente al cinturón citrícola de México, la producción ha disminuido de manera notoria, alcanzando niveles inferiores al 70% en varias huertas de naranja. En esta tesis se evaluaron metodologías novedosas que pretenden mejorar la producción y garantizar la sostenibilidad de la naranja en esta región. El Capítulo 1 describe la situación actual de los cítricos en el mundo, los desafíos que amenazan la sostenibilidad y las técnicas que actualmente se utilizan para optimizar la producción, ahorrar recursos y proteger los árboles de amenazas. En el Capítulo 2 se realizó la delimitación de zonas de manejo de acuerdo a la calidad de la fruta y producción dentro de la huerta en estudio, con la intención de que cada zona tenga un manejo individual para lograr homogenizar el rendimiento y calidad. El Capítulo 3 muestra los resultados de una metodología diseñada para la identificación de árboles enfermos en la huerta seleccionada para este trabajo. Se procesaron imágenes multiespectrales obtenidas de un vehículo aéreo no tripulado (UAV, por sus siglas en inglés) y se pusieron a prueba cinco algoritmos de aprendizaje automático para evaluar el nivel de daño en cada árbol dentro la huerta productora. El Capítulo 4 presenta un modelado de las zonas más aptas para el asentamiento de nuevas huertas productoras en la región de Rioverde, México. La generación de este modelo se realizó mediante análisis multicriterio, tomando en cuenta factores topográficos, climáticos, de suelo y de proximidad a fuentes de agua. Adicionalmente se evaluó la influencia de la variabilidad de las precipitaciones en un periodo de veinte años a través del análisis de componentes principales. Esta tesis demuestra el potencial de las técnicas de agricultura de precisión para llevar un mejor manejo del cultivo de naranja, tanto a nivel de huerta individual como a nivel regional. Por lo tanto, este trabajo puede servir como base para que autoridades y

productores tomen decisiones más informadas para garantizar la sostenibilidad de la producción y calidad de la naranja en la región de Rioverde, México.

**Palabras clave:** Agricultura de precisión, percepción remota, fitosanidad de los árboles, naranja, imágenes multiespectrales, vehículo aéreo no tripulado.

## SUMMARY

Geospatial tools and remote sensing technologies, employed across various spatial and temporal scales within precision agriculture, are integral in bolstering the sustainability of agricultural output. While citrus fruits possess significant commercial value owing to their extensive health benefits, their global production faces threats from pests, diseases, and climate change, thereby impacting the supply chain's ability to meet market demand. In the Rioverde region of San Luis Potosí, situated in the citrus belt of Mexico, a notable decrease in production has been observed, with certain orange orchards experiencing declines of over 70%. This thesis explores innovative methodologies aimed at enhancing production and ensuring the sustainability of oranges in the region. Chapter 1 provides an overview of the current global scenario of citrus fruits, highlighting sustainability challenges and existing techniques for optimizing production, resource conservation, and tree protection against threats. Chapter 2 focuses on delineating management zones based on fruit quality and production within the studied orchard. The goal was to implement tailored management strategies for each zone to achieve uniformity in production and quality. Chapter 3 presents the results of a methodology developed for identifying diseased trees within the selected orchard. Utilizing multispectral images captured by an unmanned aerial vehicle (UAV), five machine learning algorithms were tested to assess damage levels in each tree. Chapter 4 outlines a model for identifying optimal areas for establishing new orchards in the Rioverde region, Mexico. This model integrates multicriteria analysis, considering factors such as topography, climate, soil quality, and proximity to water sources. Furthermore, the impact of rainfall variability over a twenty-year period was evaluated using principal components analysis. This thesis underscores the potential of precision agriculture techniques to enhance orange management, both at the individual orchard and regional levels. Consequently, it provides valuable insights for authorities and producers to make informed decisions aimed at ensuring the sustainability and quality of orange production in the Rioverde region, Mexico.

**Keywords:** Precision agriculture, remote sensing, tree phytosanitary, orange fruit, multispectral images, unmanned aerial vehicle.

# CAPÍTULO 1

## INTRODUCCIÓN GENERAL

De acuerdo a la Organización de las Naciones Unidas para la Agricultura y la alimentación (FAO), la producción mundial de alimentos debe aumentar 70% para el 2050, con el fin de poder abastecer la demanda mundial estimada para ese año (Radoglou-Grammatikis *et al.*, 2023). En la actualidad, la agricultura tradicional está experimentando rendimientos cada vez menores debido la sobreexplotación del suelo, el uso indiscriminado de recursos naturales y agroquímicos, además del evidente cambio climático.

Los cítricos son frutales en los cuales se debería de poner especial atención ya que son los frutos de árboles más importantes del mundo, debido a su valor comercial y beneficios para la salud humana, principalmente por la aportación de vitamina C, así como por sus cualidades medicinales (Benny *et al.*, 2023). En la actualidad, la producción se ve comprometida debido al cambio climático (Zabihi *et al.*, 2016), las plagas y enfermedades (Zhang *et al.*, 2022), la variabilidad espacial en los huertos (Molin *et al.*, 2012) y a la falta de tierras aptas para nuevos cultivos de cítricos (Tercan y Dereli 2020). En la última década, la producción mundial de naranja ha disminuido más de 15 millones de toneladas (USDA, 2023).

Existen un amplio número de plagas y enfermedades de los cítricos a nivel mundial, pero se destacan dos enfermedades que han causado la mortandad de millones de árboles. *Diaphorina citri* Kuwayama (psílido asiático de los cítricos) es una plaga invasora y de rápida propagación que se encuentra en México. La peligrosidad del psílido asiático radica en que es el vector de '*Candidatus Liberibacter asiaticus*' también conocido como huanglongbing (HLB), un virus que representa una gran amenaza para la producción de cítricos, ya que debilita los árboles rápidamente, lo que provoca el amarillamiento de las hojas y la caída prematura de los frutos y eventualmente mata a los árboles en un tiempo relativamente corto desde la infección (Lin *et al.*, 2023). En los últimos años el impacto



ha sido cada más más grave y no existe una cura efectiva (Hu *et al.*, 2023). Otro virus que en la actualidad amenaza la industria citrícola en el mundo es el *Virus de la Tristeza de los Cítricos* (CVT), pertenece al género *Closterovirus*, también se encuentra distribuido en México y provoca grandes pérdidas económicas. Este virus se dispersa a través de la propagación de yemas infectadas y se transmite por pulgones (Long y Chang-Yong, 2014). Los principales síntomas de CVT son debilitamiento, picaduras en el tallo y plántula. Se estima que CVT ha causado la muerte de 100 millones de árboles cítricos (Chun-Zhen *et al.*, 2015).

La identificación temprana de enfermedades es fundamental para reducir su propagación. El hecho de no detectar a tiempo enfermedades en las plantas, aumenta la escasez de alimentos y las pérdidas económicas (Kotwal *et al.*, 2023). Gracias al desarrollo de la inteligencia artificial, se han desarrollado métodos de identificación de enfermedades, como el aprendizaje automático, aprendizaje por transferencia y aprendizaje profundo (Kotwal *et al.*, 2023).

Las especies de cítricos reclaman una elevada demanda de agua, esto se vuelve un problema importante en las zonas más áridas debido a las altas tasas de evaporación y escasez de lluvias sobre todo en verano (Pérez-Pérez *et al.*, 2012). El cambio climático está generando retos en el ámbito citrícola, los fenómenos hidrológicos extremos asociados al cambio climático han provocado inundaciones y sequías en todo el mundo (Furtak y Wolinska, 2023), ambos casos son perjudiciales para las huertas de cítricos ya que afectan el entorno del suelo y sus funciones. Sin embargo, los fenómenos hidrológicos tienen un patrón de distribución con tendencias de aumento de lluvias en las regiones del círculo polar ártico y sequías en las zonas subtropicales (Furtak y Wolinska, 2023), esto supone un grave problema para los cítricos, ya que presentan un potencial productivo alto en las regiones tropicales y subtropicales (Ruiz-Corral *et al.*, 2013).

La variabilidad espacial es una característica de los cultivos de todo el mundo (Gili *et al.*, 2017), debido a que el rendimiento y estado de salud vegetativo en una misma unidad agrícola (huerta, parcela, granja) es heterogéneo, y como consecuencia se generan

aplicaciones excesivas o deficientes de insumos como fertilizantes y agua, que irremediablemente provocan bajos rendimientos (Alesso *et al.*, 2023).

El conjunto de problemas que compromete la producción de cítricos ha generado incertidumbre entre productores de distintas regiones del mundo. Actualmente, es cada vez más habitual el abandono de huertas destinadas a la producción de cítricos (Morell-Monzó *et al.*, 2023). Por lo que, en este sentido, es urgente el diseño de medidas para garantizar la sostenibilidad de estos frutos que generan una elevada demanda mundial.

Las últimas investigaciones han sugerido que manejar de manera más eficiente las áreas de cultivos, en lugar de ampliar las tierras de producción, es la manera más eficaz de garantizar un suministro adecuado de alimentos para las necesidades actuales y futuras (Subedi *et al.*, 2023). La agricultura de precisión (AP) se posiciona como la ciencia que ayudará de manera definitiva en los problemas de producción agrícola, con el apoyo de tecnologías actuales como el internet de las cosas, los vehículos aéreos no tripulados y los sensores inalámbricos (Radoglou-Grammatikis *et al.*, 2023). Los modelos predictivos estiman que las prácticas de agricultura de precisión podrían aumentar hasta un 67% el rendimiento global para el 2050 (Jafarbiglu y Pourreza, 2022).

La agricultura de precisión es la rama de la ciencia agrícola que intenta mejorar las prácticas de manejo de cultivos para promover sistemas de producción sostenibles. El objetivo principal de la AP es maximizar el rendimiento de los cultivos y el manejo de los recursos. La AP recopila y analiza datos para generar recomendaciones de manejo, los principales recursos que usa es información de suelos, crecimiento de los cultivos, clima y otros aspectos ambientales. Para lograrlo AP utiliza instrumentos y herramientas como sensores, drones, imágenes satelitales y algoritmos de aprendizaje artificial (Idowu *et al.*, 2023). Otra de las grandes virtudes de la AP, es la reducción de plaguicidas y químicos peligrosos para la salud humana. Esto se logra realizando aplicaciones específicas dentro de la huerta y en el momento que se necesita. Esto genera beneficios colaterales al medio ambiente (Pandiyaraju *et al.*, 2023).

Estados Unidos durante muchos años ha sido uno de los productores de naranja más importantes del mundo. Sin embargo, en la actualidad es el país que más producción perdió entre los países más productores de naranja a nivel mundial, principalmente por la disminución de la producción en el estado de Florida, siendo históricamente el distrito más productor e importante de este país y una las zonas citrícolas más importantes del mundo. La producción de Florida, era mayor a la de México, un país que se encuentra en el top cinco de los mayores productores en el mundo. La principal razón de debate es Huanglongbing (Hosseinzadeh y Heck, 2023). HLB y CVT ejercen una gran presión sobre la producción de cítricos en Estados Unidos. Hoy en día se exploran todo tipo de técnicas para proteger los cultivos, la producción en ambientes protegidos como invernaderos ya se ha experimentado en ese país (Ferrarezi *et al.*, 2017), con resultados favorables, sin embargo, los costos elevados para su instalación y mantenimiento aún son una barrera para su implementación genérica en regiones citrícolas del mundo (Schumann *et al.*, 2023).

En México, también ha disminuido la producción de cítricos, debido a la baja rentabilidad. De 2010 a 2014, en el estado de Colima, 5000 hectáreas de plantaciones de cítricos cambiaron a otros rubros, lo cual se tradujo en pérdidas de más de 300 millones de pesos mexicanos de ingresos por producción de estos frutos (Rodríguez-Aguilar *et al.*, 2023). Para México, el control biológico se realiza mediante la liberación de *Tamarixia radiata*, en la actualidad se cuenta con dos laboratorios de reproducción masiva que permiten la liberación coordinada. El control químico de los productos fue aprobado por el SENASICA y validados por el INIFAP, a partir de esto, se generó un programa sustentable de manejo de la resistencia a insecticidas, para su recomendación y uso a nivel nacional. La reducción de psílicos en huertas adyacentes a una contaminada, tiene el efecto de reducir la incidencia hasta en un (90%) y la tasa de progreso (75%) del HLB, incluso en huertas abandonadas. El control del vector se realiza principalmente con productos químicos y en menor medida con control biológico mediante parasitoides, depredadores y entomopatógenos (Mora-Aguilera *et al.*, 2014). Respecto al CVT, existen diversas acciones que se realizan para evitar la infección y reducir la difusión del patógeno. El control sanitario es la primera barrera, la Norma Oficial NOM-079-FITO-

2002 rige la movilidad y producción del material propagativo libre de CVT. El monitoreo es una de las instancias primordiales para determinar la posible infección, el muestreo se realiza a través de trampas. Los muestreos se dirigen principalmente a brotes nuevos y en la mitad de la copa del árbol, por medio del daño al follaje, se detecta el vector y la enfermedad (Irracheta y Arrieta, 2012). El control de malezas, es otra de las técnicas que se realizan en el campo mexicano, con el fin de reducir plantas hospederas del áfido. La aspersión de agua de 1000 a 1200 litros/hectárea, reduce de manera significativa la densidad del áfido hasta por siete días. Una práctica común en las huertas mexicanas de naranja tanto para HLB como para CVT, es la erradicación de árboles infectados (Rodríguez y Lomelí, 2013).

México se encuentra dentro de los cinco productores de naranja más importantes a nivel mundial (Spreeen *et al.*, 2020). Se estima que la producción en el periodo 2022-2023, disminuya cerca de 400 mil toneladas (USDA, 2023). Una prolongada sequía en el noreste del país, ha afectado a estados productores de naranja como San Luis Potosí. En la Zona Media de San Luis Potosí, los municipios de Ciudad Fernández y Rioverde son los dos productores de naranja más importantes, incluso los dos municipios juntos representan poco más del 30% de la producción estatal, aunque la gran relevancia es que valor económico de su producción representa más del 60% del valor de la producción estatal y entre el 4 y el 5% de la producción nacional (SIACON, 2021). No obstante, en esta región muchos productores han optado por abandonar la producción de cítricos, principalmente por las plagas y enfermedades que han mermado la productividad de los árboles, incluso, secando huertas por completo. Algunos productores han cambiado el uso de suelo de agrícola a habitacional (uso urbano), sobre todo aquellos que están dentro o en la periferia de la mancha urbana, debido al alto valor inmobiliario que existe en la región, otros han cambiado el giro de su producción a otro tipo de cultivos.

Se realizó una encuesta entre productores de la región, para abordar distintos temas, entre ellos, el comportamiento de la producción en los últimos años, la ocurrencia de plagas y enfermedades y la posibilidad de abandonar la producción de cítricos y fraccionarla para uso habitacional o dedicarse a otros cultivos. Los resultados de la encuesta, en general muestran datos negativos respecto al futuro de los cítricos. El 100%

de los productores encuestados declara que la producción en su huerta ha disminuido en los últimos diez años y que en la actualidad sus árboles se encuentran con algún grado de daño o enfermedad. Se reportaron porcentajes en el rango del 30 al 70% de disminución, lo cual es alarmante. Más del 60% asegura tener HLB en su huerta y un 50% aseguran tener hongos que causan problemas en el tronco y hojas de los árboles. Menos del 5% piensan en fraccionar su huerta, y ese pequeño porcentaje, declara que la fracción la dividiría entre sus familiares, sin embargo, es difícil que los productores respondan esta pregunta con honestidad, ya que el fraccionamiento de las huertas se lleva a cabo bajo la ilegalidad, debido a que son tierras ejidales y la ley prohíbe su lotificación. Algunos productores han iniciado la introducción de árboles frutales como aguacate y limón persa, sin abandonar por completo la producción de naranja. Muchos productores están dispuestos a probar distintos métodos para salvar sus árboles, entre ellos las técnicas de la agricultura de precisión. Finalmente, un porcentaje importante declara que mantendrá su huerta hasta que se seque el último árbol. Garantizar la sostenibilidad de los cítricos en esta región es de suma importancia debido al papel que juega el cultivo de naranja en la economía de esta región.

En este contexto, se abordaron cuatro capítulos para esta tesis utilizando técnicas de agricultura de precisión, que se considera pueden ayudar a mejorar las condiciones de rendimiento, detectar a tiempo árboles enfermos, combatir plagas y enfermedades, así como garantizar el éxito de nuevas plantaciones de cítricos en la región. Los capítulos se describen en la sección de objetivos particulares.

## **Hipótesis**

Las técnicas de agricultura de precisión pueden ayudar en el manejo de huertas de naranja para mejorar el rendimiento de producción, la identificación temprana de árboles enfermos y la selección de nuevos sitios para el establecimiento exitoso de huertas de naranja en la región de Rioverde, México.

## **Objetivos**

Objetivo general

Delimitar zonas de manejo agrícola del cultivo de naranja (*Citrus sinensis* L. Osbeck) con la aplicación de técnicas de agricultura de precisión en una huerta de naranja en la región de Rioverde, México.

#### Objetivos particulares

- Generar zonas de manejo, en función de la calidad de la fruta y producción en la huerta de estudio.
- Clasificar árboles enfermos con imágenes de percepción remota de muy alta resolución espacial y algoritmos de aprendizaje automático.
- Analizar el impacto de la precipitación sobre la aptitud del suelo para el establecimiento de cultivos de naranja en la región de Rioverde, México.

#### LITERATURA CITADA

- Alesso, C.A., Pilatti, M.Á., Imhoff, S. y Grilli, M. (2012). Variabilidad espacial de atributos químicos y físicos en un suelo de La Pampa llana Santafesina. *Ciencia Del Suelo*, 30, 85–93.
- Benny, N., Shams, R., Dash, K.K., Pandey, V.K. and Bashir, O. (2023). Recent trends in utilization of citrus fruits in production of eco-enzyme. *Journal of Agriculture and Food Research*, 13, 100657.
- Chun-zhen, C., Jia-wei, Y., Hu-bin, Y., Xue-jun, B., Yong-yan, Z., Zhi-ming, L. and Guang-yan, G. (2015). Expressing p20 hairpin RNA of Citrus tristeza virus confers Citrus aurantium with tolerance/resistance against stem pitting and seedling yellow CTV strains. *Journal of Integrative Agriculture*, 14(9), 1767–1777.
- Ferrarezi, R. S., Wright, A. L., Boman, B. J., Schumann, A. W., Gmitter, F. G. and Grosser, J. W. (2017). Protected fresh grapefruit cultivation systems: antipsyllid screen effects on plant growth and leaf transpiration, vapor pressure deficit, and nutrition. *HortTechnology*, 27 (5), 666–674.
- Furtak, K. and Wolinska, A. (2023). The impact of extreme weather events as a consequence of climate change on the soil moisture and on the quality of the soil environment and agriculture – A review. *Catena*, 231, 107378.

- Gili, A., Álvarez, C., Bagnato, R. and Noellemeyerm, E. (2017). Comparison of three methods for delineating management zones for site-specific crop management. *Computers and Electronics in Agriculture*, 139, 213–223.
- Hosseinzadeh, S. and Heck, M. (2023). Variations on a theme: factors regulating interaction between *Diaphorina citri* and “*Candidatus Liberibacter asiaticus*” vector and pathogen of citrus huanglongbing. *Current Opinion in Insect Science*, 56, 101025.
- Hu, P., Ye, X., Song, X., Yang, M., Zhong, Y., Cen, Y., Zhang, Y., Song, Y. and Liu, Q. (2023). Nornicotine-typed insecticides: The potential insecticides with strong activity against *Diaphorina citri*. *Advanced Agrochem*, 2(2), 180–184.
- Idowu, A.R., Wachenheim, C., Hanson, E. and Sickler, A. (2023). The disposition of data from precision agricultural technologies: What do young agriculturalists think?. *Technology in Society*, 75, 102389.
- Irracheta, C. M. y Arrieta, L. C. (2012). Detección del Virus Tristeza de los Cítricos Mediante Anticuerpos Contra la Proteína Recombinante p25 de la Cápside Bajo un Sistema de Inmunoimpresión. *Revista Mexicana de Fitopatología*, 30(1), 31–42 p.
- Jafarbiglu, H. and Pourreza, A. (2022). A comprehensive review of remote sensing platforms, sensors, and applications in nut crops. *Computers and Electronics in Agriculture*, 197, 106844.
- Kotwal, J., Kashyap, R. and Pathan, S. (2023). Agricultural plant diseases identification: From traditional approach to deep learning. *Materials Today: Proceedings*, 80(1), 344–356.
- Lin, T., Guo, Y., Hu, J., Rao, W., Wei, H., Chen, X., Yang, G. and Fan, G. (2023). Toxicity risk assessment of flupyradifurone for the predatory pirate bug, *Orius strigicollis* (Poppius) (Heteroptera: Anthocoridae), a biological control agent of *Diaphorina citri* Kuwayama (Hemiptera: Liviidae). *Ecotoxicology and Environmental Safety*, 267, 115632.
- Long, Y. and Chang-yong, Z. (2014). Phylogenetic Analysis of Citrus tristeza virus Isolates of Wild Type Citrus in China. *Journal of Integrative Agriculture*, 13(12), 2669–2677.
- Molin, J.P., Colaco, A.F., Carlos, E.F. and De Mattos Junior, D. (2012). Mapping yield, soil fertility and tree gaps in an orange orchard. *Jaboticabal*, 34 (4): 1256–1265.
- Mora-Aguilera, G., Robles-García, P., López-Arroyo, J.I., Flores-Sánchez., Acevedo-Sánchez, G., Domínguez-Monge, D., Gutierrez-Espinosa, A., Loeza-Kuk, E. y González-Gómez, R. (2014). Situación Actual y Perspectivas del Manejo del HLB de los Cítricos. *Revista Mexicana de Fitopatología*, 32(2), 108–119.

- Morell-Monzó, S., Sebastián-Frasquet, M.T., Estornell, J. and Enrique, M. (2023). Detecting abandoned citrus crops using Sentinel-2 time series. A case study in the Comunitat Valenciana region (Spain). *ISPRS Journal of Photogrammetry and Remote Sensing*, 201, 54–66.
- Pandiyaraju, V., Ganapathy, S., Mohith, N. and Kannan, A. (2023). An Optimal Energy Utilization Model for Precision Agriculture in WSNs Using Multi-Objective Clustering and Deep Learning. *Journal of King Saud University - Computer and Information Sciences*, 101803.
- Pérez-Pérez, J.G., Dodd, I.C. and Botía, P., (2012). Partial rootzone drying increases water-use efficiency of lemon Fino 49 trees independently of root-to-shoot ABA signalling. *Functional Plant Biology*, 39, 366–378. <https://doi.org/10.1071/FP11269>.
- Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T. and Moscholios, I. (2020). A compilation of UAV applications for precision agriculture. *Computer Networks*, 172, 107148. <https://doi.org/10.1016/j.comnet.2020.107148>.
- Rodríguez, L. E. y Lomelí, F. J. R. (2013). Pulgón Café de los Cítricos *Toxoptera citricida* (Kirkaldy). *SAGARPA-SENASICA*. México. 28 p.
- Rodríguez-Aguilar, O., López-Collado J., Soto-Estrada, A., De la Cruz Vargas-Mendoza M. and García-Avila, C.J. (2023). Future spatial distribution of *Diaphorina citri* in Mexico under climate change models. *Ecological Complexity*, 53, 101041.
- Ruiz-Corral, J.A., Medina-García, G., González-Acuña, I.J., Flores-López, H.E., Ramírez-Ojeda, G., Ortiz-Trejo, C., Byerly-Murphy, K.F. y Martínez-Parra, R.A. (2013). Requerimientos agroecológicos de cultivos. Segunda Edición. Libro Técnico Núm. 3. INIFAP. *Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias-CIRPAC-Campo Experimental Centro Altos de Jalisco*. Tepatitlán de Morelos, Jalisco, México. 564 p.
- 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 01 de octubre de 2023.
- Schumann, A.W., Singerman, A., Ritenour, M.A., Qureshi, J. and Alferez, F. (2023). 2023–2024 Florida Citrus Production Guide: Citrus under Protective Screen (CUPS) Production Systems. *UF/IFAS Extension*, 4 pp.
- Spreen, T. H., Gao, Z., Fernandes, W. and Zansler, M. L. (2020). Global economics and marketing of citrus products. *The Genus Citrus*, 471–493. <https://doi:10.1016/b978-0-12-812163-4.00023-1>.



- Subedi, B., Poudel, A. and Aryal, S. (2023). The impact of climate change on insect pest biology and ecology: Implications for pest management strategies, crop production, and food security. *Journal of Agriculture and Food Research*, 14, 100733.
- Tercan, E. and Dereli, M.A. (2020). Development of a land suitability model for citrus cultivation using GIS and multi-criteria assessment techniques in Antalya province of Turkey. *Ecological Indicators*, 117, 106549. <https://doi.org/10.1016/j.ecolind.2020.106549>.
- United States Department of Agriculture Foreign Agricultural Service (USDA). (2023). Citrus: *World Markets and Trade*. 13 pags. Disponible en: <https://apps.fas.usda.gov/psdonline/circulars/citrus.pdf>.
- Zabihi, H., Vogeler, I., Amin, Z. M., and 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>.
- Zhang, X., Xun, Y. and Chen, Y. (2022). Automated identification of citrus diseases in orchards using deep learning. *Biosystems Engineering*, 223, 249–258.

## CAPÍTULO 2

### LAS ZONAS DE MANEJO, LA INNOVADORA TÉCNICA QUE PROMETE MEJORAR LA PRODUCCIÓN DE CÍTRICOS

#### RESUMEN

Se aborda de manera general el tema del uso de técnicas de agricultura de precisión para mejorar la producción citrícola frente a los diversos retos de la actualidad como bajos rendimientos, cambio climático, menos disponibilidad de agua, plagas y enfermedades. La delimitación de zonas de manejo es una técnica utilizada para definir áreas comunes dentro de una misma parcela que comparten las mismas características físicas y químicas, con el objetivo de optimizar la producción agrícola. La agricultura de precisión es fundamental para asegurar la producción sostenible de cítricos en el mundo.

**Palabras clave:** cítricos, agricultura de precisión, teledetección, zonas de manejo.

#### ABSTRACT

The topic of the use of precision agriculture techniques to improve citrus production in the face of various current challenges such as poor production performance, climate change, less availability of water, pests and diseases is generally addressed. Delimitation of management zones is a technique used to define areas within the same plot that share the same physical and chemical characteristics, the objective of this technique is to optimize agricultural production. Precision agriculture is essential to ensure sustainable citrus production in the world.

**Keywords:** citrus, precision agriculture, remote sensing, management zones.

## INTRODUCCIÓN

La agricultura es la principal fuente de alimentos en el mundo, la Organización Mundial de las Naciones Unidas para la Agricultura y la Alimentación (FAO) estima que para el 2050 el sector agrícola necesitará producir un 50% más de alimentos en comparación con la producción del 2012, sin embargo, las prácticas agrícolas tradicionales han perdido eficacia debido al crecimiento de la población, mayor demanda de alimentos, cambio climático, enfermedades y plagas, precios bajos para agricultores primarios y un escaso uso de tecnología (Puppala *et al.*, 2023). En países en vías de desarrollo aún predominan los métodos tradicionales agrícolas para la aplicación de insumos, es decir, se aplica una dosis uniforme sobre toda la parcela, lo cual tiene repercusiones en gastos excesivos de insumos, baja producción y daños al medio ambiente.

Los cítricos son productos agrícolas en los cuales se debería de poner especial atención ya que son los frutos de árboles más importantes del mundo, debido a su valor comercial y beneficios para la salud humana, principalmente por la aportación de vitamina C, así como por sus cualidades medicinales (Benny *et al.*, 2023). Se cultivan en las regiones tropicales y subtropicales de todo el mundo, se consumen como fruto fresco y procesado. Los países que producen más cítricos son China, Brasil y Estados Unidos (Spren *et al.*, 2020). En la actualidad la producción de cítricos está comprometida, principalmente por el cambio climático, acceso al agua y enfermedades, donde el dragón amarillo de los cítricos (huanglongbing), también conocido como HLB o enverdecimiento de los cítricos es un ejemplo destacado. El huanglongbing, es una enfermedad mortal para los cítricos, debido a su fácil propagación y agresividad, en primera instancia debilita los árboles, reduce la calidad de la fruta y finalmente conduce a la muerte de los árboles (Xu *et al.*, 2022). Esto ha generado que en los últimos años la producción de cítricos vaya a la baja, sobre todo en Estados Unidos, que es uno de los países más afectados por el huanglongbing. El monitoreo de las necesidades nutricionales, así como de plagas y enfermedades es crucial para garantizar la producción de cítricos (Moriya *et al.*, 2021).

Ante este escenario, resulta necesario modificar los hábitos en la agricultura y optar

por uso de la tecnología y la modernidad, más allá de herramientas mecánicas o vehículos motorizados que por años han ayudado a que las labores del campo sean más fáciles de realizar, hoy en día se tiene que estudiar la variabilidad del suelo, el medio ambiente y el entorno necesario para que la producción de cítricos sea más óptima y rentable. La adopción de tecnologías como los vehículos aéreos no tripulados (UAV's), robótica, internet de las cosas etc., pueden ayudar significativamente a aumentar la productividad y garantizar la sostenibilidad de la agricultura (Coulibaly *et al.*, 2022). Dentro del mundo de opciones para afrontar los retos futuros en la producción de cítricos, la agricultura de precisión ha resultado redituable y está logrando mejorar la productividad de los cultivos (Camacho y Argüello, 2018).

## **Amenazas y Riesgos Para la Sostenibilidad de los Cítricos**

### **Plagas y enfermedades: amenazas directas**

Los cítricos pertenecen a la familia *Rutaceae*, la plantación y producción ocupan el primer lugar entre los árboles frutales y son el tercer producto agrícola más importante del mundo. Además de la producción a gran escala, existen productores minoristas y en muchos países es normal encontrar algunas especies de cítricos plantados en patios de viviendas para el autoconsumo o comercio local (Cavaco *et al.*, 2018). Dentro de las variedades de cítricos destacan el limón (*Citrus lemon*), la mandarina (*Citrus reticulata*), la toronja (*Citrus paradisi*) y la naranja (*Citrus sinensis*), siendo esta última la principal especie cultivada en el mundo (Ledesma-Escobar y Luque de Castro, 2014).

Las enfermedades de los cítricos representan pérdidas millonarias en el ámbito citrícola, son causadas principalmente por hongos, virus y bacterias. Los daños por enfermedades se manifiestan en raíces, troncos, ramas, hojas y el fruto. La detección temprana de patógenos en la primera fase de la infección puede disminuir su incidencia. Los virus dependen de un hospedero para sobrevivir (en este caso el árbol) y se diseminan a través de insectos, nematodos, ácaros, entre otros. Las enfermedades bacterianas disminuyen notoriamente la producción y las más severas pueden causar la muerte de los árboles (Sáenz-Pérez *et al.*, 2019).

Dentro de las enfermedades más agresivas se encuentran *Phytophthora spp.*, causante de la enfermedad denominada gomosis, la cual causa daños en el árbol y frutos, se estima que provoca la muerte anual del 3 al 5% de cítricos (Juárez-Santillán *et al.*, 2022). virus de la tristeza de los cítricos (CVT), el cual se encuentra distribuido en todo el mundo, causando importantes pérdidas económicas, así como la muerte de millones de árboles (Pedraza *et al.*, 2016) y *Candidatus liberibacter spp.*, que causa el enverdecimiento de los cítricos (huanglongbing), en la actualidad se considera al huanglongbing la enfermedad más devastadora de los cítricos a nivel mundial y no existe control práctico y seguro, se estima que ha causado la muerte de 60 millones de árboles (Sáenz-Pérez *et al.*, 2019; Widyawan *et al.*, 2023).

Las plagas y enfermedades provocan el uso de agroquímicos, sin embargo, pueden llegar a utilizarse en exceso, afectando la salud humana y perjudicando la salud misma de los árboles debilitándolos y mermando su producción (Li *et al.*, 2022). Por otro lado, también se generan daños importantes sobre el medio ambiente, en este sentido, reducir el uso de químicos es un reto en la agricultura moderna, que se necesita afrontar con técnicas que ayuden a optimizar su uso.

### **El cambio climático y su influencia en la producción de cítricos**

El cambio climático disminuye la competitividad agrícola en países en desarrollo y desarrollados debido a la influencia del cambio de temperaturas y precipitaciones (Nugroho *et al.*, 2023). Además, provoca disturbios en el suelo que genera afectaciones en la fertilidad y productividad, los fenómenos meteorológicos extremos suponen una amenaza para la seguridad alimentaria. El cambio climático está generando retos en el ámbito cítrícola, los fenómenos hidrológicos extremos asociados al cambio climático han provocado inundaciones y sequías en todo el mundo (Furtak y Wolinska, 2023), ambos casos son perjudiciales para las huertas cítricas ya que afectan el entorno del suelo y sus funciones. De acuerdo a los datos climáticos, la temperatura del aire está aumentando, respecto a las precipitaciones se espera un aumento en el caudal en las regiones cercanas al círculo polar ártico, mientras que, las tierras secas subtropicales experimentarán una disminución en el caudal de la precipitación (Furtak y Wolinska, 2023). Esto es

verdaderamente preocupante para el ámbito cítrico ya que las zonas tropicales y subtropicales son las más aptas para estos cultivos (Ruiz-Corral *et al.*, 2013), que necesitan una alta cantidad de agua para poder ser productivos (Díaz *et al.*, 2017). Además de que existe menos disponibilidad de agua, las temperaturas más cálidas actuales intensifican la evapotranspiración y agotan rápidamente el agua del suelo, lo que induce al estrés hídrico, por tanto, se limita el potencial de rendimiento, por lo que se tienen que mejorar las técnicas para optimizar el uso del agua (Urbaneja *et al.*, 2023). El cambio climático también está relacionado con el aumento de las poblaciones de plagas y los brotes frecuentes, esto afecta negativamente la producción y disponibilidad de los cultivos, por consecuencia, es una amenaza alimentaria (Subedi *et al.*, 2023). Esto supone un problema para los cultivos cítricos que son altamente vulnerables a plagas, hongos, virus y bacterias. Por lo que controlar el cambio climático es imposible y revertirlo hoy en día es complicado, ante estas adversidades, el monitoreo de plagas y el desarrollo de herramientas y estrategias para realizar un manejo integrado es la mejor forma de adaptarse y combatir la presión que éstas generan sobre los cultivos.

Todos estos problemas han ocasionado que el abandono de huertas de naranja se observe en todo el mundo. Se estima que el 11% del área agrícola mundial está en riesgo de abandono entre 2015 y 2030 (Morell-Monzó *et al.*, 2023). El crecimiento urbano en áreas de cultivo motiva a los dueños de huertas de naranja a cambiar el uso de suelo de agrícola a otros usos.

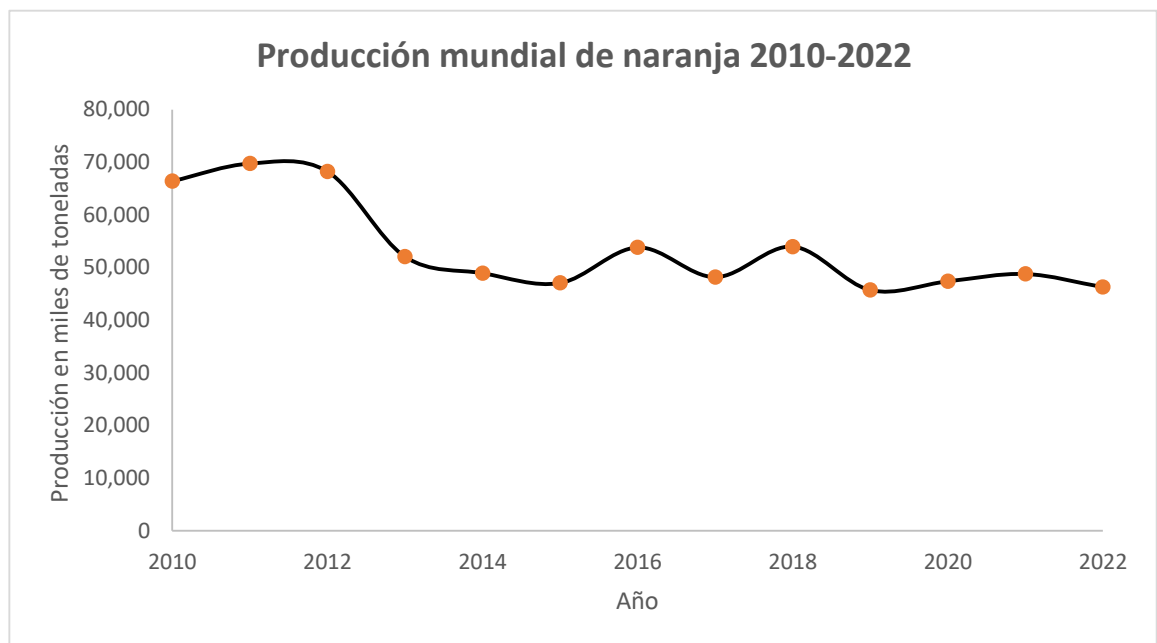
### **Producción Global de Naranja, Tendencias, Factores Influyentes y Proyecciones Futuras**

Entre los tres países líderes en la producción de naranja, Brasil y Estados Unidos han experimentado importantes descensos de la producción en los últimos años. Para el periodo de 2016, Estados Unidos disminuyó hasta un 50% su producción, siendo Huanglongbing la principal causa (Spreen *et al.*, 2020). Además, se estima que su producción de naranja caerá más de una cuarta parte a 2.3 millones de toneladas, el nivel más bajo en 56 años. Estados Unidos es el principal mercado de las exportaciones. Se

estima que la producción estadounidense de jugo caiga un 50% debido a la caída de naranjas disponibles para el procesamiento (USDA, 2023).

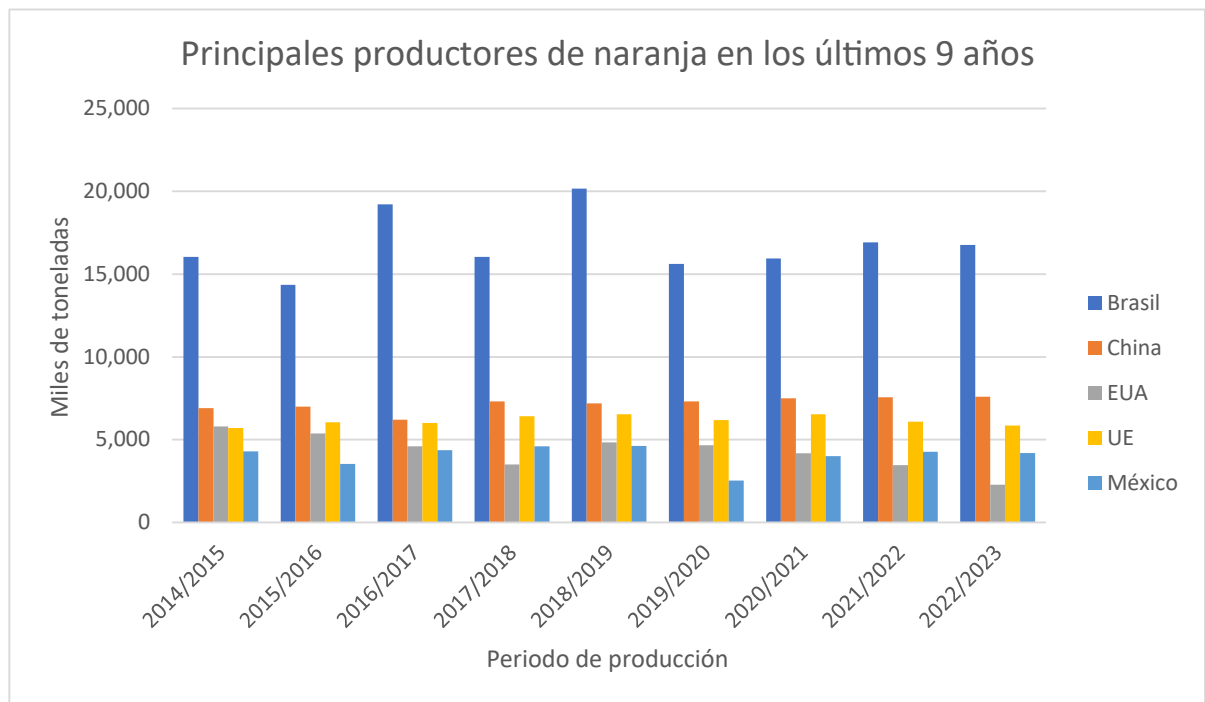
Respecto a Brasil, su producción disminuirá 179,000 toneladas con lo que se ubica en 16.8 millones por una menor carga de fruta por árbol, sin embargo, se espera que debido a un clima favorable haya un mayor peso promedio de las naranjas cosechadas. Aún con ello, Brasil es el mayor productor y se prevé que exportará tres cuartas partes de las exportaciones mundiales (USDA, 2023).

Se espera que la producción de la Unión Europea disminuya 13% quedando en 5.9 millones de toneladas debido a las condiciones de sequía y temperaturas altas principalmente en España e Italia. La menor disponibilidad se puede ver compensada con las importaciones. El consumo del fruto fresco, la disponibilidad para procesamiento y exportaciones se verán disminuidos. La mayor producción en Egipto y Sudáfrica los está convirtiendo en los principales proveedores de importaciones (USDA, 2023). En la Figura 1. Se muestra la relación de la producción mundial de naranja para el periodo 2010 – 2022.



**Figura 1.** Producción mundial de naranja, 2010-2022. Gráfica construida a partir de datos obtenidos de Statista. Fuente: <https://acortar.link/yIhTVD>, <https://acortar.link/pQ4u4V>.

Desde hace mucho tiempo, México se ha posicionado como el quinto productor mundial de naranja, sin embargo, en las últimas temporadas ha superado a Estados Unidos, en gran parte por la crisis de HLB por la que atraviesa ese país (Figura 2). Se estima que la producción en México tendrá una disminución de 395,000 toneladas como consecuencia de una prolongada sequía presente en el noreste del país, la cual ha afectado a estados productores que pertenecen a esta región como San Luis Potosí, Nuevo León y Tamaulipas. Además, en otras zonas del país también se ha observado una reducción alarmante en la producción de cítricos, tal es el caso del Estado de Colima, que en el periodo de 2010 a 2014, más de 5000 hectáreas de plantaciones de cítricos cambiaron a otros cultivos, perdiendo alrededor de 300 millones de pesos mexicanos de ingresos en este rubro (Rodríguez-Aguilar *et al.*, 2023). Otra proyección negativa, es la disminución del 18% en la producción de jugo, como resultado de menos naranjas para el procesamiento, por ende, las exportaciones se ven comprometidas (USDA, 2023).



**Figura 2.** Principales países productores de naranja en el mundo en los últimos 9 años. \*En el 2019 México sale del top 5, reingresa al siguiente año, \*\*En el 2022, Estados Unidos sale del top 5. Gráfica construida a partir de datos obtenidos de United States Department of Agriculture, disponible en <https://acortar.link/UiBQcl>.



A diferencia de las naciones antes mencionadas, Egipto está alcanzando cifras récord en su producción, ya que se prevé que aumentará 600,000 toneladas alcanzando una producción histórica de 3.6 millones de toneladas, debido al aumento del área destinada para esta actividad y al clima favorable que ha persistido en el país. Los principales países de destino de las exportaciones incluirán a la Unión Europea, Rusia y Arabia Saudita (USDA, 2023).

En Sudáfrica la producción aumentará ligeramente hasta alcanzar una producción récord de 1.6 millones de toneladas, resultado de la mejora de las condiciones meteorológicas y de una mayor área destinada a la producción de naranja. Se estima que el consumo interno disminuirá, por consiguiente, las exportaciones alcanzaran niveles sin precedentes en este país. Sudáfrica se ha mantenido como uno de los países más importantes en el ámbito de exportaciones, mientras que los países de la Unión Europea son los países del mundo que más naranja importan (USDA, 2023).

Se estima que la producción mundial de jugo de naranja será un 9% menor, a 1.5 millones de toneladas. La disminución en este rubro se debe a la reducción de la fruta disponible para el procesamiento en cuatro de los principales productores (Brasil, la Unión Europea, México y Estados Unidos).

Los expertos del Centro de Cooperación Internacional en Investigación Agrícola para el Desarrollo (CIRAD), pronostican que la temporada 22/23 será la más baja en el hemisferio norte en los últimos nueve años debido a los fenómenos meteorológicos extremos producidos por el cambio climático (European Commission, 2022).

Considerando el análisis realizado, vienen tiempos difíciles para la producción global de cítricos, especialmente la naranja. Estados Unidos ha sufrido considerablemente debido a la enfermedad Huanglongbing (Hosseinzadeh y Heck, 2023), con una drástica reducción en su producción. Florida, la que una vez fue líder en producción de naranjas en los Estados Unidos, ha disminuido su producción al punto de ser superada por California, a pesar de las condiciones áridas de este último (Milne *et al.*, 2018). Mientras que México, reporta tendencias similares.

## **Métodos de Manejo Utilizados en Huertas de Naranjas con la Presencia de Enfermedades y Bajo Rendimiento de los Cítricos**

En la actualidad, las principales causas que conducen a bajos rendimientos de cítricos son: plagas y enfermedades, difícil acceso al agua, la variabilidad del suelo y deficientes prácticas agrícolas. En este sentido, se revisan algunas prácticas modernas que intentan afrontar estos problemas.

### **Influencia de la teledetección en la agricultura**

La percepción remota ha facilitado la cuantificación de la variación espacial y temporal de los cultivos con una amplia gama de resoluciones espacial (tamaño de píxel) y temporal (periodicidad con que se puede adquirir una fotografía o escena del mismo lugar) (Wang *et al.*, 2023). Las imágenes satelitales para aplicaciones agrícolas se han utilizado por mucho tiempo, hoy en día las imágenes obtenidas mediante vehículos aéreos no tripulados, también conocidos como drones, se han vuelto populares y son objetivo de muchas investigaciones debido a su alta resolución espacial.

Uno de los objetivos de la agricultura de precisión es la toma de decisiones informadas sobre la siembra, el riego, la fertilización y el control de plagas (Puppala *et al.*, 2023), lo que conlleva a la aplicación de insumos en el sitio específico. En este sentido, las imágenes obtenidas por UAV's resultan con una gran ventaja, ya que con la alta resolución espacial que brindan y la programación de vuelos acorde a las necesidades, se puede llevar un control y manejo a nivel de árbol. Otra novedad, es que los sensores multiespectrales e hiperespectrales se pueden adaptar sobre los UAV's, a precios al alcance de los productores (Méndez-Vázquez *et al.*, 2019). Por otro lado, las imágenes aéreas obtenidas por medio de diferentes sensores, facilitan el cálculo de índices de vegetación que se pueden correlacionar con los mapas de producción. Algunos estudios previos demuestran que el dosel de los árboles frutales y el NDVI están correlacionados con el rendimiento final y se pueden aplicar para estimar el rendimiento del huerto (Mirhaji *et al.*, 2021). Además, la percepción remota resulta una buena opción para el monitoreo de los cultivos cítricos. En caso de involucrar grandes extensiones de tierra, las imágenes de satélite pueden ser una buena opción si, el estudio se reduce al nivel de parcela o huerta, las

imágenes obtenidas por medio UAV's son una mejor opción. Por otro lado, las imágenes de satélite de acceso gratuito manejan resoluciones espaciales muy bajas con las que es imposible llevar un seguimiento a nivel de árbol (ejemplo Landsat) y los productos con altas resoluciones espaciales suelen ser costosos y con desventajas en la resolución temporal, es decir que se dificulta el acceso a escenas de fechas específicas. La temporalidad de las imágenes de satélite se ve afectada si mejora su resolución espacial, por ejemplo, MODIS, que entrega datos diarios, pero con resoluciones espaciales que van desde los 250 m hasta 1 km, en cambio Sentinel-2 entrega resoluciones espaciales de hasta 10 m, pero su resolución temporal es de 10 días. En el Cuadro 1, se muestra una comparativa entre sensores remotos utilizados para estudios agrícolas.

**Cuadro 1** Comparación de sensores remotos.

<b>Sensor</b>	<b>Resolución temporal</b>	<b>Resolución espacial (m)</b>	<b>Tamaño de escena (km)</b>
<b>MODIS</b>	Diaria	250, 500, 1000	2,330 x 23030
<b>Landsat 9, última misión enviada</b>	8 días	15, 30	185 x 185
<b>Sentinel-2</b>	10 días	10, 20, 60	290 x 290
<b>UAV</b>	*	**	***

\*Definida por el usuario de acuerdo a la necesidad.

\*\* Definida por el usuario y dependiendo la altura de vuelo (puede llegar a ser menor de 1 cm).

\*\*\* Definida por el usuario dependiendo la altura de vuelo.

Existen estudios que, por su naturaleza, necesitan imágenes que abarquen grandes áreas, un ejemplo es la investigación que realizaron Morell-Monzó *et al.* (2023) quienes evaluaron el abandono de huertas de naranja en Valencia, España. Estos investigadores utilizaron imágenes satelitales Sentinel-2 (con una resolución de entre 10-20 m), con las que evaluaron tres estados del cultivo (no productivo, productivo y abandonado) a nivel de huerta, muestreando más de 600 hectáreas en diferentes visitas a campo.

El estudio de Morell-Monzó *et al.* (2023) tiene la limitante de no poder distinguir la edad de árbol, tomando en cuenta que la edad promedio a la que empieza la producción en un árbol de naranja es de 5 años, los investigadores se guiaron con la copa de los árboles, es decir en una plantación donde predomine el suelo desnudo o árboles con poca copa, se les asigna la clase "no productivos": sin embargo, la imagen de Sentinel-2 no es capaz de distinguir entre un árbol que aún no está en edad productiva y un árbol con problemas de salud o que atraviesa deficiencia de riego. En este sentido, las imágenes de los UAV's podrían ser un buen complemento para que este trabajo eleve su efectividad. En la literatura existen muchos ejemplos como este caso.

### **Concepto y aplicación de la agricultura de precisión**

En la actualidad el cambio climático impacta negativamente en la producción de productos agrícolas, además, cada día aumenta la demanda de alimentos en todo el mundo. En este sentido, los métodos de cultivo deben adaptarse a las condiciones actuales, a través de tres principales acciones: lograr mayores rendimientos, evitar el consumo excesivo de recursos y minimizar los impactos ambientales. La agricultura de precisión (AP) prioriza estas acciones promoviendo la idea de una producción agrícola sostenible. Para lograrlo la AP implementa tecnología de sensores e información tratada con software especializado para generar recomendaciones en función de la variabilidad espacial y temporal de los cultivos (Gemtos *et al.*, 2013; Maheswari *et al.*, 2021; Mirhaji *et al.*, 2021).

La AP generalmente involucra cuatro procesos importantes, que incluyen, 1) recolecta datos del suelo, clima y cultivos, 2) procesamiento de la información recolectada 3) generación de mapas de desempeño y 4) preinscripción de recomendaciones para tomar decisiones informadas sobre la siembra, el riego, la fertilización y el control de plagas (Du *et al.*, 2008; Puppala *et al.*, 2023). Los principales recursos tecnológicos empleados en la AP son: sistemas de posicionamiento global (GPS), sistema de información geográfica (GIS), percepción remota o teledetección (RS), tecnología de tasa variable (VRT), mapeo de desempeño, sensores y tecnologías de la información (Maldonado Jr. y Barbosa, 2016). Los beneficios de la AP incluyen, aumento del rendimiento mediante la aplicación de dosis necesarias, reducción de la expansión de tierras destinadas al uso agrícola, diseño

de estrategias de riego, mecanización y automatización de procesos y el mejoramiento de variedades de alto rendimiento. Hoy en día los sistemas sostenibles son cruciales para la existencia del ser humano, en los últimos años se ha visto un aumento significativo del uso de AP por parte de los administradores de granjas de todo el mundo.

El sector agrícola contribuye de manera importante en el cambio climático a través del agotamiento de recursos, degradación del suelo, emisiones de químicos en el aire y generación de desechos, y al mismo tiempo se ve afectado por ello (Cabot *et al.*, 2022). En este sentido, es importante realizar prácticas agrícolas que garanticen la producción sostenible, optimizando recursos y cuidando los recursos naturales como el agua y el suelo. La agricultura de precisión se consolida como la tecnología del presente y del futuro en el manejo de sistemas agrícolas, puntualmente en la producción de cítricos, ya que toma en cuenta la variabilidad espacial con respecto a las características físicas y químicas del suelo y la nutrición de las plantas responsables del fruto, también procura optimizar el uso de recursos como el agua y la disminución del uso de agroquímicos (Molin *et al.*, 2012; Zhang *et al.*, 2017). Técnicas como el aprendizaje profundo y el internet de las cosas eficientizan más la AP, lo que facilita a los agricultores la gestión de sus operaciones para obtener mayores beneficios y satisfacer de manera sostenible el suministro de alimentos (Saranya *et al.*, 2023).

Las técnicas de la agricultura de precisión pueden resultar de gran ayuda para atender los problemas actuales y mejorar la producción optimizando recursos, sin embargo, la adopción de la AP es complicada en países en vías de desarrollo, principalmente por la falta de conocimiento de los beneficios, por la falta de mano de obra calificada y los costos que involucra la AP. Para el caso de la producción cítricos se traza la misma línea, incluso en países como México que es uno de los cinco productores más importantes en el mundo (Bonales-Revuelta *et al.*, 2022). En los últimos años, los UAV's han ganado relevancia, sin embargo, su uso en las prácticas agrícolas se da mayoritariamente en países desarrollados como Estados Unidos, Australia y la Unión Europea. La información obtenida con UAV's ayuda a los agricultores en las etapas de pre cosecha, cosecha y postcosecha. Los UAV's están logrando la automatización total gracias a la intervención de la inteligencia artificial como las redes neuronales y algoritmos genéticos (Puppala *et*

*al.*, 2023).

La detección oportuna y precisa de plagas y enfermedades en cítricos es fundamental para mitigar su y evitar pérdidas económicas para los productores (Qiang *et al.*, 2023). La implementación de métodos no destructivos como la percepción remota y el uso de los algoritmos de clasificación automáticos, han mejorado el monitoreo, identificación, diferenciación y la determinación de la gravedad de plagas y enfermedades en árboles (Zhang *et al.*, 2019). Lan *et al.* (2020) utilizaron un sensor multiespectral comercial montado en un vehículo aéreo no tripulado en un vuelo a baja altitud para detectar huanglongbing en cítricos, utilizaron VI índices de vegetación, análisis de correlación y reducción de variables utilizando análisis de componentes principales y AutoEncoder. Además, compararon el rendimiento de cinco algoritmos de aprendizaje automático, logrando resultados de hasta un 100% de precisión en la detección de la enfermedad.

Moussaid *et al.* (2022) utilizaron un conjunto de datos que comprende cinco años de datos históricos, incluido el clima, el riego, la fertilización, el tratamiento fitosanitario y otra información de campo, para predecir el rendimiento de los cítricos en los huertos. El objetivo fue desarrollar un modelo de aprendizaje automático capaz de predecir el rendimiento del huerto varios meses antes de la cosecha. Probaron múltiples algoritmos con técnicas de optimización de parámetros y validación cruzada para evitar el sobreajuste. El algoritmo Orthogonal Matching Pursuit arrojó una puntuación de error absoluto medio (MAE) de 0,2489 y una puntuación de error cuadrático medio (MSE) de 0,0843. Para mejorar aún más la predicción, los investigadores incorporaron información espectral de imágenes de satélite. Esta inclusión mejoró las puntuaciones a 0,2315 (MAE) y 0,0748 (MSE). Chen *et al.* (2023) diseñaron un modelo basado en un algoritmo genético No-Denominado II (NSGA-II) para un esquema óptimo de asignación de agua con la intención de mejorar la calidad y rendimiento de los cítricos en China. Para ello pusieron a prueba seis modelos de rendimiento hídrico, los modelos Minhas y el modelo Q-Rao fueron los que mejor predijeron el rendimiento de los cítricos y la calidad de agua, además de impulsar un ahorro del agua, a través de la asignación óptima. Los hallazgos de esta investigación serán útiles para formular estrategias de riego adecuadas en el contexto de

del cambio climático y escasez de agua, para lograr una producción eficiente y sostenible de los cítricos.

La fumigación es un tema preocupante, ya que puede resultar en excesivas aplicaciones de productos químicos, distribución desigual, la dispersión de pesticidas en el aire, así como daño a la salud humana (Hafeez *et al.*, 2023). El uso de UAV's es prometedor para superar estos retos. Katsigiannis *et al.* (2016) demostraron el uso eficiente de UAV's para la gestión del agua en un huerto de granados, para ello midieron algunos índices como el NDVI y el estrés hídrico. Sus resultados indicaron que con la ayuda de imágenes obtenidas por medio de UAV's se puede evitar un riego inadecuado, así como aplicaciones excesivas de insumos. Balaji *et al.* (2018) diseñaron un UAV con diferentes componentes como Wi-Fi, Bluetooth, puertos HDMI y USB etc., además usaron el lenguaje gratuito de programación Python, con el objetivo de reducir el uso de insumos agrícolas como agroquímicos y agua, dentro de los objetivos de esta investigación, se incluyó disminuir la mortandad de agricultores que realizan aplicaciones manuales de agroquímicos. Sus resultados experimentales son prometedores, de acuerdo a sus estimaciones, el diseño del UAV propuesto puede tener ahorros en un rango de 20 a 90% en agroquímicos, consumo de agua y recursos humanos. Martínez-Guanter *et al.* (2019) desarrollaron un sistema de fumigación aérea de pesticidas para olivos y cítricos, considerando la carga útil en el UAV. El sistema propuesto estuvo en un rango de bombeo de entre 0.10 y 0.22 litros/min. Sus resultados experimentales fueron exitosos, ahorrando aproximadamente 7 dólares/ha y reduciendo el uso de agroquímicos. Anand y Goutam (2019) diseñaron un UAV llamado AeroDrone para monitoreo de campo y fumigación de agroquímicos. El objetivo era minimizar el tiempo de fumigación y la pérdida de pesticida. Los resultados demostraron que el trabajo realizado por este sistema integrado de cuadricópteros fue eficiente y el tiempo de misión de cada cuadricóptero fue casi el mismo. Este plan mostró buenos resultados, aunque sólo se probó en un área de cultivo rectangular.

Finalmente, antes los problemas ocasionados por plagas y enfermedades, así como el crecimiento de la mancha urbana sobre cultivos de naranja, es importante difundir entre los productores y las instancias tomadoras de decisiones la propuesta de zonas potenciales para el establecimiento de nuevas áreas destinadas a esta actividad. En este sentido, los

modelados de zonas aptas para el establecimiento de nuevos cultivos de cítricos se pueden generar a partir de la integración de factores ambientales, climáticos, topográficos y de suelo en un entorno SIG, y con base en la opinión de expertos, delimitar estas áreas. A través de los recursos de AP, entre ellos, percepción remota, SIG, GPS se pueden delimitar áreas potenciales con métodos como el análisis multicriterio (MCDA). Se revisaron trabajos que se han desarrollado en el mundo y utilizaron esta metodología aplicada en cítricos, a continuación, se mencionan algunos, Elsheikh *et al.* (2013) desarrollaron una herramienta para evaluar la aptitud de las tierras agrícolas para la planificación de cultivos tropicales y subtropicales, incluidos los cítricos en Malasia. Zabihi *et al.* (2015) mapearon la aptitud del suelo para la planificación sostenible de cítricos en una región del norte de Irán utilizando el proceso de red analítica (ANP) dentro de un entorno SIG.

Los gobiernos deberían de poner más atención en la AP y difundir las ventajas de su uso, ya que los beneficios son muchos en materia de seguridad alimentaria, económica y la reducción del impacto ambiental por excesos de la agricultura, los subsidios en la adquisición de herramientas y tecnología de AP o los beneficios fiscales puede motivar a los productores para incursionar en su uso (Huber *et al.*, 2023).

### **Otros métodos utilizados**

La producción de cítricos en ambientes protegidos es un campo relativamente nuevo y poco estudiado a nivel global (Ferrarezi *et al.*, 2017). Esta técnica tiene la capacidad de aislar plagas y enfermedades como el HLB y bichos que no caben por la malla permeable, además tienen el potencial de mejorar la productividad y calidad de los frutos (Schumann *et al.*, 2023). Ferrarezi *et al.* (2019) reportaron los resultados de su investigación, donde por 6 años pusieron a prueba la producción de toronjas en cuatro micro invernaderos de 1080 m<sup>2</sup> (30 m de ancho × 36 m de largo × 4,3 m de alto) con ventilación pasiva y la utilización de malla sombra, la estructura principal de estos contenedores fue madera tratada a presión. En el experimento se compararon los árboles de los invernaderos contra árboles sembrados a cielo abierto, los factores que se compararon fueron, exposición a enfermedades, calidad del árbol, rendimiento y calidad de la fruta. Los resultados mostraron que los árboles productores en invernaderos exhibieron un mayor rendimiento



y calidad de la fruta, además estuvieron excluidos de enfermedades. Concluyen que, la producción en ambiente protegido ofrece fruta de alta calidad para el mercado de fruta fresca. Otras ventajas incluyen, menor caída de fruta en cualquier etapa de crecimiento y en general mejor estado de salud de los árboles, por otro lado, el manejo de aplicación de fertilizantes y riego es más sencilla (Schumann *et al.*, 2023). Sin embargo, existen algunos obstáculos a superar como los altos costos de los invernaderos, para 2019 oscilaban entre 10.5 y 11 dólares por metro cuadrado, además, los árboles tienen vulnerabilidad a plagas como ácaros de la roya de los cítricos (*Phyllocoptruta oleivora*), la cochinilla (*Unaspis citri*), los trips (*Frankliniella spp.*), y enfermedades como la mancha grasienta de los cítricos (*Mycosphaerella citri*) (Ferrarezi *et al.*, 2019).

El uso de hormonas naturales reguladores del crecimiento de plantas, se han aplicado anteriormente en otro tipo de vegetación, sin embargo, se ha demostrado que puede utilizarse en cítricos para el control de plagas. Widyawan *et al.* (2023) propusieron la aplicación de ácido salicílico (SA) y ácido fenilacético (PAA) empapado en el suelo y en las plántulas de cítricos, obteniendo resultados de hasta 78% de efectividad en el control de "*Candidatus Liberibacter asiaticus*" en naranja dulce, su técnica resulta prometedora, además es fácil de aplicar y es ambientalmente segura.

Los problemas por falta de agua se agudizan en las zonas tropicales y subtropicales, ante esta situación, técnicas como el secado parcial de raíces (PRD, por sus siglas en inglés), pueden resultar interesantes para optimizar al máximo el uso del agua. Este proceso consiste en provocar un déficit de agua en la zona de las raíces lo que genera que existan zonas húmedas y zonas secas dentro del sistema radicular. El objetivo de esta práctica es inducir la producción de ácido abscísico (ABA) en las zonas parcialmente secas que sirven para que las hojas reduzcan la apertura estomatal y de esta manera reducir la pérdida de agua, por otro lado, las raíces húmedas mantienen el follaje con buen estado hídrico (Düring y Loveys, 1996; Dry *et al.*, 2000; Pérez-Pérez *et al.*, 2012). PRD es una gran ventaja frente a técnicas convencionales de riego deficitario, ya que la reducción de agua por medio de este método ayuda a separar las respuestas de señalización bioquímica al déficit hídrico en la parte seca de la zona radicular de los efectos físicos de la conductancia estomática reducida debido a la menor disponibilidad de agua, permitiendo

procesos de desarrollo asociados, por ende los procesos de desarrollo asociados con el crecimiento de las plantas permanezcan imperturbables (Hutton y Loveys, 2011; Romero-Conde *et al.*, 2014). PRD es una técnica lleva al cultivo a límite, solo debe aplicarse en árboles sanos y bien establecidos (Hutton & Loveys, 2011). Si se realiza PRD con un riego deficitario, se puede provocar un estrés severo en los árboles, lo cual puede tener repercusiones negativas (Romero-Conde *et al.*, 2014). Kirda *et al.* (2007) aplicaron el método de PRD en el cultivo de mandarina, en el que aplicaron 6 tratamientos, que incluían riego tradicional y riego completo. El estudio se realizó por dos años y a pesar de que el mejor rendimiento lo dio el riego tradicional y el riego completo, las diferencias con el método PRD fueron pequeñas y no estadísticamente significativas. Hutton y Loveys (2011) utilizaron el método PRD en cultivo de naranja dulce, en una región de Australia. El estudio se realizó por 5 años en sistema de riego por goteo, obtuvieron resultados positivos logrando disminuir 40% el uso de agua y solamente se reportaron pérdidas del rendimiento por menos del 9%. Otros estudios también obtuvieron resultados exitosos con PRD en naranja dulce (Consoli *et al.*, 2014; Mossad *et al.*, 2018), en limón (Pérez-Pérez *et al.*, 2012) y toronja (Kusakabe *et al.*, 2016).

### **Definición y Aplicación de las Zonas de Manejo Agrícola**

La agricultura tradicional considera las parcelas agrícolas como una sola unidad, lo cual provoca aplicaciones uniformes, no obstante, dentro de una parcela existe heterogeneidad lo cual puede provocar una asignación inadecuada de insumos agrícolas (Wang *et al.*, 2023). El manejo tradicional y uniforme de los cultivos de cítricos, no toma en cuenta la variabilidad física, química y nutricional en el entorno que se desarrollan los árboles. Esta situación puede generar aplicaciones excesivas en zona con altos niveles de nutrientes y deficientes en zonas con bajos niveles de nutrientes. En la actualidad, el manejo uniforme de cultivos agrícolas se ha empezado a reemplazar por la identificación de zonas homogéneas dentro de un mismo huerto de cultivo (Córdoba *et al.*, 2016). Las técnicas de la agricultura de precisión, tienen el potencial de definir zonas de manejo dentro una parcela teniendo en cuenta patrones de variabilidad espacial y temporal de los cultivos y suelos de las parcelas (Oldoni *et al.*, 2019; Wang *et al.*, 2023).

El concepto de las zonas de manejo en los cultivos se remonta a finales de los 90's y el inicio de la década de los 2000. Varios investigadores proponían el uso de imágenes aéreas para estudiar la respuesta de los cultivos y tratar de predecir la cosecha. Blackmore (2000) utilizó fotografías aéreas, datos de satélites meteorológicos y Landsat, así como SIG, concluyendo que la teledetección tenía potencial para dar seguimiento dinámico y la estimación del rendimiento de muchos cultivos en distintas regiones. Diker *et al.* (2001) estudiaron durante 3 años la respuesta de rendimiento de maíz en dos campos comerciales de Colorado, USA. Para ello delinearon tres zonas de manejo. Los resultados indicaron que podían evaluar la variabilidad del rendimiento en el tiempo y espacio sin tener que promediar datos de diferentes años.

Las zonas de manejo son regiones dentro de un campo que agrupan características homogéneas particulares del cultivo, del suelo y terreno. Para la zonificación de los cultivos se deben considerar múltiples agentes causantes de la variabilidad y la respuesta de los cultivos agrícolas (Córdoba *et al.*, 2016). Las fuentes de información para la delimitación de las zonas de manejo pueden incluir: a) datos de rendimiento, b) datos de propiedades físicas y químicas del suelo, c) imágenes, d) imágenes de sensores proximales y remotos, e) topografía y f) la combinación entre ellos (Taylor *et al.*, 2007). Existen parámetros que debido a su estabilidad temporal no sufren cambios significativos en su variabilidad espacial a lo largo de los años, algunos de estos parámetros incluyen elevación, textura del suelo, las pendientes y su orientación (Colaço *et al.*, 2020).

El manejo de cultivos por zonas y los mapas de características físicas de los huertos ayuda a los agricultores a tomar decisiones informadas y más precisas, lo cual les ayuda a aumentar los rendimientos netos y optimizar el uso de los recursos, minimizando costos y daños al medio ambiente, pero también sirven para obtener algunos índices valiosos, como el índice de decisión de fecha óptima de cosecha y el índice de maduración de la fruta (Cavaco *et al.*, 2018; Colaço *et al.*, 2019; Wang *et al.*, 2023). Existen técnicas de la agricultura de precisión que son costosas como tractores guiados por GPS, sembradoras y aspersoras automáticas, entre otros. Mejorar la producción por medio de zonas de manejo suele ser menos costoso para los pequeños y medianos productores, ya que no necesariamente se requiere de maquinaria costosa (Méndez-Vázquez *et al.*, 2019). Las

zonas de manejo serán fundamentales para disminuir las pérdidas en la producción de cítricos en todo el mundo (Zhang *et al.*, 2017).

Existe una amplia gama de herramientas y metodologías para implementar las zonas de manejo de formas sencillas y accesibles. Para el mapeo de factores de respuesta y de zonificación, se usan métodos de interpolación geoestadística como el peso de la distancia inversa (IDW, por sus siglas en inglés) y el método kriging, técnicas como el álgebra raster para el manejo de imágenes RGB o multiespectrales georreferenciadas, con las que se obtienen índices de vegetación o inventarios (Méndez-Vázquez *et al.*, 2019). Para definir la forma y el número de las zonas de manejo, se puede usar desde metodologías simples hasta estadísticamente complejas. Algunos de los más populares incluyen polígonos dibujados a mano en mapas de rendimiento o imágenes, clasificación de rendimiento normalizada, clasificación supervisada o no supervisada de imágenes, filtros espectrales, análisis de conglomerados de k-medias duras, conglomerados de k-medias difusas, entre otras (Taylor *et al.*, 2007).

La delimitación de las zonas de manejo se realiza con diferentes enfoques como la mejora de la producción agrícola (Gavioli *et al.*, 2019), la disminución de daños al medio ambiente (Breunig *et al.*, 2020), analizar la calidad de la fruta, el control de plagas (Méndez-Vázquez *et al.*, 2019), y con fines de riego (Ouazaa *et al.*, 2022).

Algunos ejemplos destacados de investigaciones recientes que se han realizado en el mundo en este ámbito son Méndez-Vázquez *et al.* (2019) utilizaron la delimitación de zonas de manejo con el enfoque de manejo de plagas, propusieron añadir al modelo de zonas de manejo, capas ecológicas representadas por modelos de patrones de distribución de plagas dentro del campo generados a través de modelos de distribución de especies y mapas ambientales de alta definición, con el fin de superar obstáculos como el dinamismo de las plagas. Sus resultados fueron exitosos con plagas virtuales y existe un alto nivel de confianza para aplicar en casos de plagas reales. Colaço *et al.* (2020) delinearon y aplicaron las zonas de manejo durante cinco temporadas de crecimiento en dos parcelas de naranja, en Brasil, para reducir el uso de insumos, y estudiar la respuesta de la viabilidad económica, energética y de nutrientes de la fertilización. En una de las parcelas

los gastos y ganancias se mantuvieron similares, sin embargo, en la otra aumentaron cerca del 35% las ganancias, aún hace falta afinar a detalles para que la metodología funcione en cualquier parcela en que se aplique, no obstante, estos resultados demuestran que las ganancias de los productores se pueden ver favorecidas de manera considerable. Ouazaa *et al.*, (2022) delinearon zonas de manejo para mejorar el riego y la producción en un sistema de cultivos mixtos en Tolima, Colombia. Para ello utilizaron variables del suelo como: capacidad de campo, agua disponible en el suelo, resistencia a la penetración del suelo, fósforo disponible y el contenido de bases intercambiables (Ca+ Mg/K). Además, utilizaron los métodos geoestadísticos de Fisher-Jenks, Análisis de conglomerados y K-medias difusas. Sus resultados demuestran que con la delimitación de zonas de manejo es posible el ahorro de agua en el riego, además de generar mejores rendimientos.

### **Abandono de Huertos: Una Problemática Latente**

El abandono de tierras agrícolas compromete el abastecimiento de cítricos y en general de alimentos en la actualidad y en el futuro. Se estima que 11% del área agrícola mundial se encuentra en riesgo de abandono para el periodo 2015-2030 (Morell-Monzó *et al.*, 2023). Entre las principales causas del abandono destacan, la poca rentabilidad que representa esta actividad para los productores debido a los retos actuales, el avance de la mancha urbana sobre las áreas productoras y el poco interés de nuevas generaciones por la agricultura, sobre todo de pequeños y medianos productores. Otra causa destacada dentro de la problemática actual en el desarrollo agrícola, es la resistencia a usar nuevas tecnologías en la agricultura principalmente de los productores que han utilizado las técnicas tradicionales toda la vida. Algunos de los factores que más influyen en la adopción de las tecnologías de precisión son la percepción de los resultados esperados, las preferencias de riesgo y la rentabilidad percibida de la tecnología (Huber *et al.*, 2023).

Sin duda estas situaciones comprometen la distribución de cítricos, además, esto también puede generar un aumento significativo de precios en el mercado. El uso desmedido de productos químicos que se usan para controlar plagas vuelve a los cultivos de cítricos más vulnerables, también se pueden generar afectaciones a la población debido a la contaminación del suelo y del ambiente. Cada región del mundo tiene sus leyes

respecto al uso de agroquímicos, sin embargo, en cítricos se sabe que se usan algunos productos como glifosato, abamectina, piridaben, oxiclورو de cobre y permanganato de potasio.

Con técnicas como la delimitación de zonas de manejo y la tecnología actual se puede llegar cada vez más al control total de los cultivos y saber las necesidades al nivel más básico en un área de producción, nos referimos a la planta y/o árbol. Esto conduce a una producción más homogénea que esta fuera del alcance de la agricultura tradicional. Sin duda, las ventajas son sobresalientes, mayores ingresos para los productores, un efecto positivo es la disminución de productos agresivos para el medio ambiente y menor desgaste de recursos naturales.

## **CONCLUSIONES**

La dinámica actual de la agricultura, el crecimiento de la población, la resistencia de las plagas y las enfermedades y el cambio climático, causan que la agricultura tradicional se vea limitada para satisfacer la demanda actual y futura de cítricos, por lo que, urge aplicar nuevas técnicas que efficienten el manejo de huertos de cítricos. El uso de la tecnología GIS, teledetección y software especializado es cada vez es más necesario en pequeños y medianos productores. Las zonas de manejo parecen influir notoriamente de manera positiva en la mejora de la producción y sostenibilidad de la citricultura de todo el mundo.

## **LITERATURA CITADA**

Anand, K. and Goutam, R. (2019). Anand K, G R. An Autonomous UAV for Pesticide Spraying. *International Journal of Trend in Scientific*, 3, 986–990.

- Balaji, P.B., Radha, S., Katuri, R. and Mareedu, K. (2018). Design of UAV (Drone) for Crop, Weather Monitoring and for Spraying Fertilizers and Pesticides. *International Journal for Research Trends and Innovation*, 3(3), 2456–3315.
- Benny, N., Shams, R., Dash, K.K., Pandey, V.K. and Bashir, O. (2023). Recent trends in utilization of citrus fruits in production of eco-enzyme. *Journal of Agriculture and Food Research*, 13, 100657.
- Blackmore, S. (2000). The interpretation of trends from multiple yield maps. *Computers and Electronics in Agriculture*, 26(1), 37–51.
- Bonales-Revuelta, J., Musule, R., Navarro-Pineda, F.S. and García, C.A. (2022). Evaluating the environmental performance of orange production in Veracruz, Mexico: a life cycle assessment approach. *Journal of Cleaner Production*, 131002. <https://doi.org/10.1016/j.jclepro.2022.131002>.
- Breunig, F.M., Soares-Galvao, L., Dalagnol, R., Dauve, C.E., Parraga, A., Santi, A.L., Della-Flora, D.P. and Chen, S. (2020). Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. *International Journal of Applied Earth Observation and Geoinformation*, 85, 102004. <https://doi.org/10.1016/j.jag.2019.102004.9>.
- Cabot, M.I., Lado, J., Clemente, G. and Sanjuán, N. (2022). Towards harmonised and regionalised life cycle assessment of fruits: A review on citrus fruit. *Sustainable Production and Consumption*, 33, 567–585.
- Camacho, A. & Arguello, H. (2018). Smartphone-based application for agricultural remote technical assistance and estimation of visible vegetation index to farmer in Colombia: AgroTIC. *Proceedings of SPIE*.
- Cavaco, A.M., Antunes, M.D., Guerra, R., Rosendo, M., Pires, R., Brázio, A., Silva, L., Alfonso, A.M., and Panagopoulos, T. (2018). Fruit quality survey techniques to optimize crop management in citrus orchards. *Acta horticulturae*, 1194, 135–142.
- Chen, F., Cui, N., Jiang, S., Wang, Z., Li, H., Lv, M., Wang, Y., Gong, D. and Zhao, L. (2023). Multi-objective deficit drip irrigation optimization of citrus yield, fruit quality and water use efficiency using NSGA-II in seasonal arid area of Southwest China. *Agricultural Water Management*, 287, 108440.
- Colaço, A. F., Molin, J.P., Rosell-Polo, J.R. and Escolà, A. (2019). Spatial variability in commercial orange groves. Part 2: relating canopy geometry to soil attributes and historical yield. *Precision Agriculture*, 20, 805–822.
- Colaço, A.F., Pagliuca, L.G., and Romanelli, T.L. (2020). Economic viability, energy and nutrient balances of site-specific fertilisation for citrus. *Biosystems engineering*, 200, 138–156.

- Consoli, S., Stagno, F., Rocuzzo, G., Cirelli, G.L. and Intrigliolo, F. (2014). Sustainable management of limited water resources in a young orange orchard. *Agricultural Water Management*, 132, 60–68. <https://doi.org/10.1016/j.agwat.2013.10.006>.
- Córdoba, M.A., Bruno, C.I., Costa, J.L., Peralta, N.R. and Balzarini, M.G. (2016). Protocol for multivariate homogeneous zone delineation in precision agriculture. *Biosystems Engineering*, 143, 95–107.
- Coulibaly, S., Kamsu-Foguem, B., Kamissoko, D. and Traore, D. (2022). Deep learning for precision agriculture: A bibliometric analysis. *Intelligent Systems with Applications*, 16, 200102.
- Díaz, I., Mazza, S.M., Combarro, E.F., Giménez, L.I. and Gaiad, J.E. (2017). Machine learning applied to the prediction of citrus production. *Spanish Journal of Agricultural Research*, 15(2), 1–12.
- Diker, K., Buchleiter, G. W., Farahani, H. J., Heermann, D. F. and Brodahl, M. K. (2001). Frequency analysis of yield for delineating management zones. *Proceedings of the 6th International Conference on Precision Agriculture and Other Precision Resources Management, Minneapolis, MN, USA*, 817–827.
- Dry, P.R., Loveys, B.R. and During, H. (2000). Partial drying of the rootzone of grape. I. Transient changes in shoot growth and gas exchanges, *Vitis*, 39, 3–7.
- Du, Q., Chang, N., Yang, C. and Srilakshmi, K.R. (2008). Combination of multispectral remote sensing, variable rate technology and environmental modeling for citrus pest management. *Journal of Environmental Management*, 86, 14–26.
- Düring, H. and Loveys, B.R. (1996). Stomatal patchiness of field-grown Sultana leaves: diurnal changes and light effects. *Vitis*, 35 (1), 7–10.
- Elsheikh, R., Mohamed Shariff, A.R.B., Amiri, F., Ahmad, N.B., Balasundram, S.K. and Soom, M.A.M. (2013). Agriculture Land Suitability Evaluator (ALSE): a decision and planning support tool for tropical and subtropical crops. *Computers and Electronics in Agriculture*, 93, 98–110. <https://doi.org/10.1016/j.compag.2013.02.003>.
- European Commission. (2022). Meeting of the Expert Group Fruit and Vegetables Market Observatory – CITRUS FRUIT. Commission européenne/Europese Commissie, 1049 Bruxelles/Brussel, Belgique/belgië. Disponible en: <https://agriculture.ec.europa.eu>.
- Ferrarezi, R. S., Wright, A. L., Boman, B. J., Schumann, A. W., Gmitter, F. G. and Grosser, J. W. (2017). Protected fresh grapefruit cultivation systems: antipsyllid screen effects on plant growth and leaf transpiration, vapor pressure deficit, and nutrition. *HortTechnology*, 27 (5), 666–674.



- Ferrarezi, R.S., Qureshi, J.A., Wright, A.L., Ritenour, M.A. and Macan, N.P.F. (2019). Citrus production under screen as a strategy to protect grapefruit trees from huanglongbing disease. *Frontiers in plant science*, 10, 1598.
- Furtak, K. and Wolinska, A. (2023). The impact of extreme weather events as a consequence of climate change on the soil moisture and on the quality of the soil environment and agriculture – A review. *Catena*, 231, 107378.
- Gavioli, A., de Souza, E.G., Bazzi, C.L., Schenatto, K. and Betzek, N.M. (2019). Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. *Biosystems Engineering*, 181, 86–102. <https://doi.org/10.1016/j.biosystemseng.2019.02.01>.
- Gemtos, T., Fountas, S., Tagarakis, A. and Liakos, V. (2013). Precision Agriculture Application in Fruit Crops: Experience in Handpicked Fruits. *Procedia*, 8, 324–332.
- Hafeez, A., Husain, M.A., Singh, S.P., Chauhan, A., Khan, M.T., Kumar, N., Chauhan, A. and Soni, S.K. (2023). Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information Processing in Agriculture*, 192-203. <https://doi.org/10.1016/j.inpa.2022.02.002>.
- Hosseinzadeh, S. and Heck, M. (2023). Variations on a theme: factors regulating interaction between *Diaphorina citri* and “*Candidatus Liberibacter asiaticus*” vector and pathogen of citrus huanglongbing. *Current Opinion in Insect Science*, 56, 101025.
- Huber, R., Spati, K. and Finger, R. (2023). A behavioural agent-based modelling approach for the ex-ante assessment of policies supporting precision agriculture. *Ecological Economics*, 212, 107936. <https://doi.org/10.1016/j.ecolecon.2023.107936>.
- Hutton, R.J. and Loveys, B.R. (2011). A partial root zone drying irrigation strategy for citrus—Effects on water use efficiency and fruit characteristics. *Agricultural Water Management*, 98(10), 1485–1496.
- Juárez-Santillán, L.F., Tejada-Tapia, Y., Reyes-Gómez, J.P., López-Ceballos, J.J., Martínez-Aguilar, K. y Armenta-Barrios, J.A. (2022). Peróxido de hidrógeno y bicarbonato de sodio para control de gomosis en el cultivo de naranja Valencia. *Revista Multidisciplinaria de Ciencia Innovación y Desarrollo*, 1(1), 15–22.
- Katsigiannis, P., Misopolinos, L., Liakopoulos, V., Alexandridis, T.K. and Zalidis, G. (2016). An Autonomous Multi-Sensor UAV System for Reduced-Input Precision Agriculture Applications. *Mediterranean Conference on Control and Automation*, 60-64.

- Kirda, C, Topaloğlu, F., Topçu, S. and Kaman, H. (2007). Mandarin Yield Response to Partial Root Drying and Conventional Deficit Irrigation, Turkish. *Journal of Agriculture and Forestry*, 31(1), 1–10.
- Kusakabe, A., Contreras-Barragan, B.A., Simpson, C.R., Enciso, J.M., Nelson, S.D. and Melgar, J.C. (2016). Application of partial rootzone drying to improve irrigation water use efficiency in grapefruit trees. *Agricultural Water Management*, 178, 66–75. <https://doi.org/10.1016/j.agwat.2016.09.012>.
- Lan, Y., Huang, Z., Deng, X., Zhu, Z., Huang, H., Zheng, Z., Lian, B., Zeng, G., and Tong, Z. (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>.
- Ledesma-Escobar, C.A. and Luque de Castro, M.D. (2014). Towards a comprehensive exploitation of citrus. *Trends in Food Science & Technology*, 39, 63–75.
- Li, Z., Zhang, Y., Zhao, Q., Cui, Y., He, Y., Li, J., Yang, Q., Lin, Z., Wang, C., Liang, G. and Jiao, B. (2022). Determination, distribution and potential health risk assessment of insecticides and acaricides in citrus fruits of China. *Journal of Food Composition and Analysis*, 111, 104645. <https://doi.org/10.1016/j.jfca.2022.104645>.
- Maheswari, P., Raja, P., Apolo-Apolo, O.E. and Pérez-Ruiz, M. (2021). Intelligent Fruit Yield Estimation for Orchards Using Deep Learning Based Semantic Segmentation Techniques—A Review. *Frontiers in Plant Science*, 12, 684328.
- Maldonado Jr. W. and Barbosa J.C. (2016). Automatic green fruit counting in orange trees using digital images. *Computers and Electronics in Agriculture*, 127, 572–581.
- Martinez-Guanter, J., Agüera, P., Agüera, J. and Pérez-Ruiz, M. (2019). Spray and economics assessment of a UAV-based ultra-low-volume application in olive and citrus orchards. *Precision Agriculture*, 226–243. <https://doi.org/10.1007/s11119-019-09665-7>.
- Méndez-Vázquez, L.J., Lira-Noriega, A., Lasa-Covarrubias, R. and Cerdeira-Estrada, S. (2019). Delineation of site-specific management zones for pest control purposes: Exploring precision agriculture and species distribution modeling approaches. *Computers and Electronics in Agriculture*, 167, 105101.
- Milne, A. E., Teiken C., Deledalle F., Van den Bosch F., Gottwald T. and McRoberts, N. (2018). Growers' risk perception and trust in control options for huanglongbing citrus-disease in Florida and California. *Crop Protection*, 114, 177–186.
- Mirhaji, H., Soleymani, M., Asakereh, A. and Mehdizadeh, S.A. (2021). Fruit detection and load estimation of an orange orchard using the YOLO models through simple

- approaches in different imaging and illumination conditions. *Computers and Electronics in Agriculture*. 191, 106533.
- Molin, J.P., Colaco, A.F., Carlos, E.F. and De Mattos Junior, D. (2012). Mapping yield, soil fertility and tree gaps in an orange orchard. *Jaboticabal*, 34(4), 1256–1265.
- Morell-Monzó, S., Sebastián-Frasquet, M.T., Estornell, J. & Enrique, M. (2023). Detecting abandoned citrus crops using Sentinel-2 time series. A case study in the Comunitat Valenciana region (Spain). *ISPRS Journal of Photogrammetry and Remote Sensing*, 201, 54–66.
- Moriya, É. A. S., Imai, N. N., Tommaselli, A. M. G., Berveglieri, A., Santos, G. H., Soares, M. A., Marino, M., and 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>.
- Mossad, A., Scalisi, A. and Lo Bianco, R. (2018). Growth and water relations of field-grown ‘Valencia’ orange trees under long-term partial rootzone drying. *Irrigation Science*, 36, 9–24.
- Moussaid A., El Fkihi S. and Zennayi, 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>.
- Nugroho, A.D., Prasada, I.Y. and Lakner, Z. (2023). Comparing the effect of climate change on agricultural competitiveness in developing and developed countries. *Journal of Cleaner Production*, 406, 137139. <https://doi.org/10.1016/j.jclepro.2023.137139>.
- Oldoni, H., Silva-Terra, V.S., Timm, L.C., Júnior, C.R. and Becker-Monteiro, A. (2019). Delineation of management zones in a peach orchard using multivariate and geostatistical analyses. *Soil & Tillage Research*, 191, 1–10.
- Ouazaa, S., Jaramillo-Barrios, C.I., Chaali, N., Quevedo-Amaya, Y.M., Calderon-Carvajal, J.E. and Montenegro-Ramos, O. (2022). Towards site specific management zones delineation in rotational cropping system: Application of multivariate spatial clustering model based on soil properties. *Geoderma Regional*, 30, e00564. <https://doi.org/10.1016/j.geodrs.2022.e00564>.
- Pedraza, M. R., Ponce, S. J. L., Quintanar, A. E. A., Valdés, M. D. y Villareal, R. G. (2016). Una Amenaza Agrícola Mundial: El Virus de la Tristeza de los Cítricos y su Vector el Pulgón Café *Toxoptera citricida*. *Artrópodos y Salud*, 3(1), 30–36 p.

- Pérez-Pérez, J.G., Dodd, I.C.a and Botía, P., (2012). Partial rootzone drying increases water-use efficiency of lemon Fino 49 trees independently of root-to-shoot ABA signalling. *Functional Plant Biology*, 39, 366–378. <https://doi.org/10.1071/FP11269>.
- Puppala, H., Peddinti, P.R.T., Tamvada, J.P., Ahuja, J., and Kim, B. (2023). Barriers to the adoption of new technologies in rural areas: The case of unmanned aerial vehicles for precision agriculture in India. *Technology in Society*, 74, 102335.
- Qiang, J., Liu, W., Li, X., Guan, P., Du, Y., Liu, B. and Xiao, G. (2023). Detection of citrus pests in double backbone network based on single shot multibox detector. *Computers and Electronics in Agriculture*, 212, 108158.
- Rodríguez-Aguilar, O., López-Collado J., Soto-Estrada, A., De la Cruz Vargas-Mendoza M., and García-Avila, C.J. (2023). Future spatial distribution of *Diaphorina citri* in Mexico under climate change models. *Ecological Complexity*, 53, 101041.
- Romero-Conde, A., Kusakabe, A. and Melgar, J.C. (2014). Physiological responses of citrus to partial rootzone drying irrigation. *Scientia Horticulturae*, 169, 234–238. <https://doi.org/10.1016/j.scienta.2014.02.022>.
- Ruiz-Corral, J.A., Medina-García, G., González-Acuña, I.J., Flores-López, H.E., Ramírez-Ojeda, G., Ortiz-Trejo, C., Byerly-Murphy, K.F. y Martínez-Parra, R.A. (2013). Requerimientos agroecológicos de cultivos. Segunda Edición. Libro Técnico Núm. 3. INIFAP. *Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias-CIRPAC-Campo Experimental Centro Altos de Jalisco*. Tepatitlán de Morelos, Jalisco, México. 564 p.
- Sáenz-Pérez, C.A., Osorio-Hernández, E., Estrada-Drouaillet, B., Poot-Poot, W.A., Delgado-Martínez, R. y Rodríguez-Herrera, R. (2019). Principales enfermedades en cítricos. *Revista Mexicana de Ciencias Agrícolas*, 10(7), 1653–1665. <https://doi.org/10.29312/remexca.v10i7.1827>.
- Saranya, T., Deisy, C., Sridevi, S. and Anbananthen, K.S.M. (2023). A comparative study of deep learning and Internet of Things for precision agriculture. *Engineering Applications of Artificial Intelligence*, 122, 106034. <https://doi.org/10.1016/j.engappai.2023.106034>.
- Schumann, A.W., Singerman, A., Ritenour, M.A., Qureshi, J. and Alferez, F. (2023). 2023–2024 Florida Citrus Production Guide: Citrus under Protective Screen (CUPS) Production Systems. *UF/IFAS Extension*, 4 pp.
- Spreen, T. H., Gao, Z., Fernandes, W. and Zansler, M. L. (2020). Global economics and marketing of citrus products. *The Genus Citrus*, 471–493. <https://doi:10.1016/b978-0-12-812163-4.00023-1>.

- Subedi, B., Poudel, A. and Aryal, S. (2023). The impact of climate change on insect pest biology and ecology: Implications for pest management strategies, crop production, and food security. *Journal of Agriculture and Food Research*, 14, 100733.
- Taylor, J.A., McBratney, A.B. and Whelan, B.M. (2007). Establishing Management Classes for Broadacre Agricultural Production. *Agronomy Journal*, 99(5), 1366–1376.
- United States Department of Agriculture Foreign Agricultural Service (USDA). (2023). Citrus: *World Markets and Trade*. 13 pags. Disponible en: <https://apps.fas.usda.gov/psdonline/circulars/citrus.pdf>.
- Urbaneja, A., Ciancio, A., Droby, S., Hoddle, M., Liu, J. and Tena, A. (2023). Recent advances in biological control of citrus pests and diseases. *Biological Control*, 184, 105271. <https://doi.org/10.1016/j.biocontrol.2023.105271>.
- Wang, N., Xu, D., Xue, J., Zhang, X., Hong, Y., Peng, J., Li, H., Mouazen, A.M., He, Y., and Shi, Z. (2023). Delineation and optimization of cotton farmland management zone based on time series of soil-crop properties at landscape scale in south Xinjiang, China. *Soil and Tillage Research*, 231, 105744.
- Widyawan, A., Al-Seleh, M.A., El Komy, M.H., Al Dhafer, H.M. and Ibrahim, Y.E. (2023). Potential of resistance inducers for citrus huanglongbing management via soil application and assessment of induction of pathogenesis-related protein genes, *Heliyon*, 9, e19715.
- Xu, C., Alhejaili, W., Saifullah, S., Khan, A., Khan, J. and 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>.
- Zabihi, H., Ahmad, A., Vogeler, I., Said, M.N., Golmohammadi, M., Golein, B. and Nilashi, M. (2015). Land suitability procedure for sustainable citrus planning using the application of the analytical network process approach and GIS. *Computers and Electronics in Agriculture*, 117, 114–126. <https://doi.org/10.1016/j.compag.2015.07.014>.
- Zhang, X., Zhang, J., Li, L., Zhang, Y. and Yang, G. (2017). Monitoring Citrus Soil Moisture and Nutrients Using an IoT Based System. *Sensors*, 17(3), 447. <https://doi.org/10.3390/s17030447>.
- Zhang, J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K. and Huang, W. (2019). Monitoring plant diseases and pests through remote sensing technology: A review. *Computers and Electronics in Agriculture*, 165, 104943.

## CAPÍTULO 3

### GENERACIÓN DE ZONAS DE MANEJO A PARTIR DEL NDVI, PRODUCCIÓN Y CALIDAD DE LA FRUTA EN ÁRBOLES DE CÍTRICOS EN UNA HUERTA DE LA REGIÓN CENTRO DE MÉXICO

#### RESUMEN

La naranja Valencia, una fruta de gran valor comercial a nivel mundial, es el cultivo más destacado en la región de Rioverde, México. Sin embargo, en la última década, diversos factores como plagas, escasez de agua y cambios climáticos han afectado negativamente el rendimiento y la calidad de la fruta. En este estudio, se llevó a cabo un inventario en un huerto de naranja Valencia con el propósito de definir zonas de manejo según la calidad de la fruta y la producción. El huerto de estudio actualmente alberga 592 árboles productivos, de los cuales se seleccionaron aleatoriamente 65 para este análisis. Se recolectaron 5 naranjas de cada árbol para evaluar sus atributos de calidad, incluyendo diámetro, grosor de la cáscara, peso individual, número de semillas, sabor y producción por árbol. Se empleó el algoritmo de clúster, con el cual se definieron tres zonas de calidad y producción. La Zona de Manejo 1 (ZM1) cubre 10526.13 m<sup>2</sup>, la Zona de Manejo 2 (ZM2) ocupa 19842.34 m<sup>2</sup>, y la Zona de Manejo 3 (ZM3) abarca 9359.89 m<sup>2</sup>. Según los atributos evaluados, la ZM1 se distingue por ser la zona con la más alta calidad y producción, mientras que la ZM3 representa las condiciones menos favorables. También, se calculó el NDVI promedio en cada zona utilizando un sensor multiespectral en un dron, confirmando que la vegetación más saludable se encuentra en la ZM1 (0.46), mientras que la ZM3 presenta vegetación menos vigorosa (0.41). En términos de producción promedio por árbol, la ZM3 alcanza los 47 kg, la ZM2 llega a los 133 kg y la ZM1 lidera con 164 kg. Estos resultados brindan una base sólida para que los productores tomen decisiones informadas con el objetivo de aplicar el concepto de zonas de manejo en la producción de naranja en la región.

**Palabras clave:** zonas de manejo, agrupación clúster, percepción remota, agricultura de presión, vehículo aéreo no tripulado.

## ABSTRACT

Valencia orange, a fruit of great commercial value worldwide, is the most prominent crop in the Rioverde region, Mexico. However, in the last decade, various factors such as pests, water scarcity and climate changes have negatively affected the yield and quality of the fruit. In this study, an inventory was carried out in a Valencia orange orchard with the purpose of defining management zones according to the quality of the fruit and production. The study orchard currently hosts 592 productive trees, of which 65 were randomly selected for this analysis. 5 oranges were collected from each tree to evaluate their quality attributes, including diameter, peel thickness, individual weight, number of seeds, flavor, and production per tree. Cluster algorithm was used, with which three quality and production zones were defined. Management Zone 1 (ZM1) covers 10526.13 m<sup>2</sup>, Management Zone 2 (ZM2) occupies 19842.34 m<sup>2</sup>, and Management Zone 3 (ZM3) covers 9359.89 m<sup>2</sup>. According to the attributes evaluated, ZM1 is distinguished as the area with the highest quality and production, while ZM3 represents the least favorable conditions. Also, the average NDVI in each area was calculated using a multispectral sensor on a drone, confirming that the healthiest vegetation is found in ZM1 (0.46), while ZM3 presents less vigorous vegetation (0.41). In terms of average production per tree, ZM3 reaches 47 kg, ZM2 reaches 133 kg and ZM1 leads with 164 kg. These results provide a solid basis for producers to make informed decisions with the objective of applying the concept of management zones in orange production in the region.

**Keywords:** management zones, clustering algorithm, remote sensing, precision agriculture, unmanned aerial vehicle.

## INTRODUCCIÓN

La naranja es la fruta más consumida en todo el mundo y desempeña un papel fundamental en la dieta de millones de personas. Su exquisito sabor y versatilidad, la han convertido en un alimento esencial tanto para el consumo en fresco como para la

elaboración de jugos, postres y otros productos alimenticios (Benny *et al.*, 2023). Además de su valor nutricional, la naranja es una fuente importante de ingresos para los agricultores y la industria de alimentos en muchas regiones del planeta (Riolo *et al.*, 2024).

Sin embargo, en las últimas décadas, la producción de naranja ha enfrentado una serie de problemas que amenazan su calidad y cantidad (Ezrari *et al.*, 2022). Factores como el cambio climático, la presión de plagas y enfermedades (Moriya *et al.*, 2019; Xu *et al.*, 2022), y la disponibilidad de recursos hídricos han impactado significativamente en los huertos de naranjos (Chen *et al.*, 2023). Estos problemas han llevado a una disminución en la calidad de la fruta y una reducción en la producción en varios lugares del mundo (Spren *et al.*, 2020).

En este contexto, se vuelve crucial encontrar enfoques y estrategias que permitan un manejo más eficiente y sustentable de los huertos de naranjos. La delimitación de zonas de manejo, basada en la evaluación de la calidad de la fruta y el rendimiento a nivel de árbol, se presenta como una herramienta prometedora en esta búsqueda (Colaço *et al.*, 2019). Esta técnica, respaldada por la percepción remota y los sistemas de información geográfica, permite un manejo preciso de los recursos y una toma de decisiones informada para mejorar tanto la calidad, como la cantidad, dentro del proceso de producción de naranja (Cavaco *et al.*, 2018).

Este trabajo se enfocó en la generación y comparación de zonas de manejo en función de la producción y calidad del fruto de naranja Valencia, así como el papel que juega el NDVI en la predicción de zonas de manejo en un huerto localizado en Rioverde, México con el propósito de identificar las zonas de manejo del cultivo. Las variables de interés fueron diámetro del fruto, grosor de cáscara del fruto, peso individual del fruto, semillas por fruto, sabor del fruto y producción por árbol. Esto se realizó mediante muestreo georeferenciado mediante coordenadas cartográficas, a nivel de árbol individual y el uso de un sistema de información geográfica para la representación espacial de la variabilidad.



## **MATERIALES Y MÉTODOS**

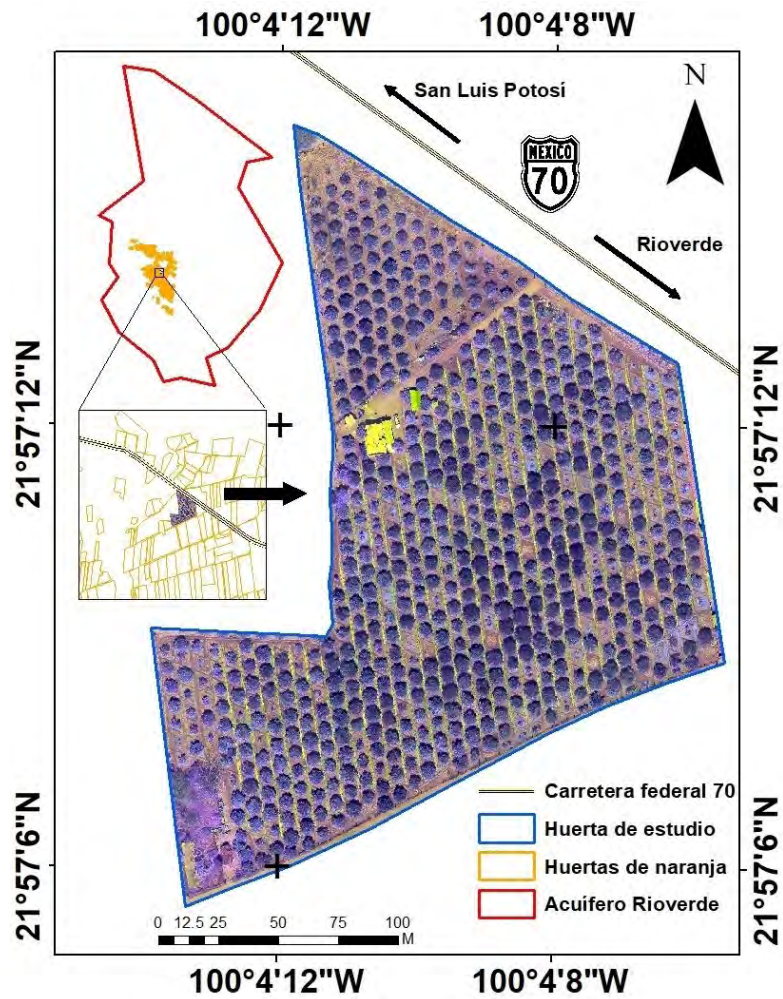
### **Área de Estudio**

La huerta de estudio se ubica en una región productora de naranjas de aproximadamente 5000 hectáreas en el municipio de Ciudad Fernández, S.L.P., México. En la actualidad, esta huerta alberga 632 árboles de naranja de la variedad Valencia, plantados en filas con una separación de 8 m x 8 m (Figura 1). La huerta está delimitada por un contorno irregular de 4 hectáreas donde las hileras de árboles están orientadas en dirección este-oeste. En esta región se llevan a cabo dos ciclos de cosecha. La primera cosecha suele ser la más productiva y valiosa y va durante los meses de junio y julio, mientras que el segundo corte se realiza en octubre y noviembre donde se cosechan las naranjas que aún estaban verdes en el primer corte. Las condiciones climáticas de esta región provocan que se pueda cosechar naranja cuando en otras regiones del país escasea, lo que genera que el producto tenga un mayor valor en el mercado.

### **Inventario de Árboles**

Se llevó a cabo un inventario de los árboles a través del procesamiento de un ortomosaico generado a partir de imágenes capturadas durante un vuelo con un dron sobre la huerta, así como información recolectada en campo. En la huerta, se encontraron árboles en plena producción, árboles jóvenes en proceso de producción, árboles secos que ya no generan frutos y áreas que, por el momento, no contenían ningún árbol. Estos espacios podían estar vacíos debido a la reciente eliminación de árboles secos o enfermos, o porque se estaban preparando para futuras plantaciones. Cada árbol, independientemente de su estado, y cada área sin plantación fueron debidamente etiquetados en un software SIG (Sistema de Información Geográfica) para obtener una visión completa de la capacidad máxima de la huerta en términos de árboles. En total, se registraron 677 puntos en el inventario. A cada punto del inventario se le asignó una clave única que consta de un número de columna (C) y un número de árbol (A), siguiendo el formato C3A5, por ejemplo. Sin embargo, en el contexto de este estudio, se excluyeron los espacios vacíos sin árboles, así como los árboles secos y aquellos que no estaban en producción. No

obstante, se mantuvieron las claves asignadas en el inventario completo de puntos, por lo que solo se consideró un total de 592 árboles en plena producción para el presente estudio.

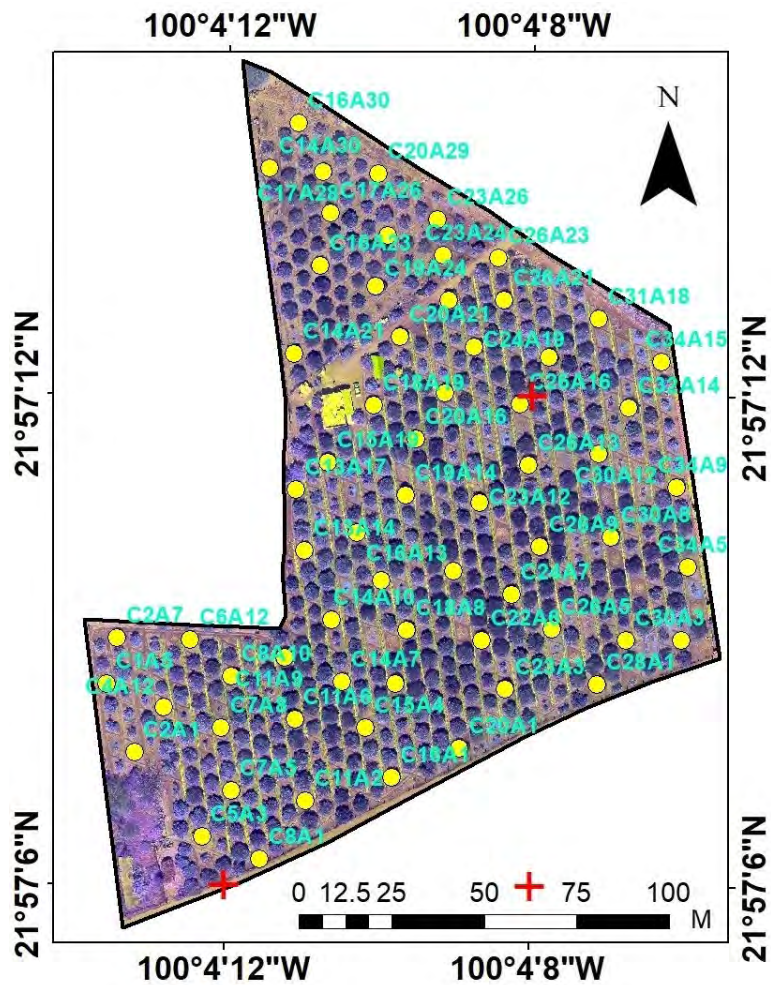


**Figura 1.** Ubicación del Área de estudio.

### **Selección de Árboles Para el Muestreo**

El inventario de árboles realizado en la huerta muestra que existen 592 árboles en condiciones de producción, de los cuales se seleccionaron 65 de manera aleatoria para obtener los datos de calidad del fruto y producción. Además de ser elegidos de manera

aleatoria, se procuró que los árboles seleccionados estuvieran distribuidos por toda el área de la huerta (Figura 2).



**Figura 2.** Inventario de árboles seleccionados para el muestreo.

Los árboles seleccionados fueron etiquetados de manera física con una etiqueta colgante para su fácil identificación en campo (Figura 3).



**Figura 3.** Etiquetado de árbol en campo.

### **Variables Medidas**

Los árboles de cítricos absorben nutrientes durante todo el año, sin embargo, existe más demanda durante la floración y formación de la fruta. El *N* y el *K* son los elementos más abundantes en el fruto (Molina, 2000). El nutriente más vital para los cultivos es el *N*, los fertilizantes nitrogenados son relativamente de bajo costo, por lo tanto, es común que se usen en exceso (Wang *et al.*, 2023). Una mayor tasa de humedad relativa ( $HR > 50\%$ ) influye en el crecimiento de la naranja ya que fomenta cáscaras más delgadas en la fruta sin llegar a ser cascarás finas o débiles y mejora la producción de jugo en calidad y cantidad (Anderson, 1996). Las temperaturas mínimas y máximas extremas son factores limitantes para la producción de naranja porque pueden provocar la caída de las flores. En el área de estudio, la temperatura media mínima varía entre  $11.2^{\circ}\text{C}$  a  $14.7^{\circ}\text{C}$ , y la temperatura media máxima fluctúa entre  $25.9^{\circ}\text{C}$  a  $30^{\circ}\text{C}$ . En este sentido, dichos valores se encuentran dentro del rango óptimo para la producción de naranja, que se encuentra

entre 24°C y 32°C (Zabihi *et al.* 2015). La producción en el área de estudio depende tanto de las precipitaciones como del agua subterránea.

Se midieron seis atributos que tienen relación con la calidad de la fruta, así como la producción individual de los árboles. Los atributos medidos fueron: 1) diámetro de cada naranja, 2) grosor de la cáscara, 3) peso por naranja individual, 4) total de semillas por naranja y 5) sabor. Se calculó el promedio de cada naranja individual de estos atributos. Además, se obtuvo la producción total de cada árbol muestreado. Se recolectó una muestra de cinco naranjas por cada árbol seleccionado, obteniendo un total de 325. La técnica para seleccionar las cinco naranjas consistió en cortar tres naranjas alrededor de la copa del árbol en diferentes alturas, una por dentro de la copa y en el centro del árbol y otra en lo alto del árbol, esto por la posible influencia en el tiempo de exposición de luz solar, así como el acceso a nutrientes por parte del fruto dependiendo de la ubicación donde se encuentre. Las naranjas secas y en mal estado fueron descartadas, ya que estas no son tomadas en cuenta para la venta cuando se realiza la cosecha. Las naranjas verdes tampoco se consideraron para este muestreo ya que, en este caso, estas se quedan madurando en el árbol para la segunda etapa de la cosecha. Las naranjas fueron recolectadas y almacenadas en bolsas previamente marcadas con la clave de árbol del que fueron cortadas, de esta manera los parámetros que posteriormente se calcularon pudieron ser referenciados en el inventario.

Días previos a la cosecha y apoyados de herramientas como báscula digital, regla métrica, vernier digital, cuchillos y exprimidores se obtuvieron los resultados para cada variable, excepto la producción por árbol la cual se llevó a cabo durante la cosecha. Es importante la variedad y tipo de naranja cuando se habla de atributos como el peso, tamaño y sabor, sin embargo, en este estudio se trabajó con naranja de la variedad Valencia, por lo cual, los atributos y el valor comercial que deriva de ellos están en función solamente de esta variedad.

Para obtener el peso promedio, se pesaron las cinco naranjas de cada árbol y posteriormente se promediaron, según los datos del productor de manera general en su huerta, se necesitan en promedio cuatro o cinco naranjas para obtener un kilogramo de

buena calidad en un árbol sano y de seis a siete naranjas en un árbol débil o enfermo. En los últimos años, debido a las plagas y enfermedades, las naranjas suelen ser más pequeñas y se necesitan hasta ocho naranjas para obtener un kilogramo en los árboles más débiles, las cuales son de muy mala calidad. El productor primario vende las naranjas de su huerto por el total de toneladas que pese la cosecha, es conveniente para el productor que las naranjas pesen tanto como sea posible, pero en el mercado no siempre la naranja más grande es la más atractiva para la venta, normalmente la gente asocia una naranja valencia grande con poco sabor, además, una cáscara gruesa puede elevar el peso de la naranja. Si la planta tuvo déficit de nutrientes puede tener un tamaño grande pero poco jugo y mala calidad por lo que no tendrá un buen sabor. La deficiencia de  $K$  y  $B$  se asocia a frutos pequeños, la deficiencia de  $Ca$ ,  $Mn$  y  $Fe$ , está relacionado con frutos de bolsas de jugo secos, arrugados, reducción del cuaje del fruto, puntos de goma al interior de los gajos, así como color pálido de la fruta (Molina, 2000).

El diámetro promedio se realizó cortando de la manera más simétrica posible las cinco naranjas del árbol, posteriormente con el apoyo de la regla métrica se midió una de las mitades de cada naranja desde la cara exterior de la cascara, por un lado, hasta la cara exterior por el otro lado, los resultados de cada una de las cinco mitades se promediaron para obtener el diámetro promedio de las naranjas para cada árbol. En esta región en la actualidad se obtienen naranjas más pequeñas que los promedios de otras zonas del país (Ariza-Flores *et al.*, 2010). Una naranja grande no necesariamente significa que pese mucho, algunas naranjas con déficit de nutrientes o riego pueden estar grandes, pero sin mucho jugo por lo que pueden estar más ligeras que otra naranja un poco más pequeña, pero con una cantidad importante de jugo. La deficiencia de  $P$  puede generar piel más gruesa y rugosa, la de deficiencia de  $N$ ,  $Ca$  y  $Mg$  pueden provocar frutos pequeños y además maduración precoz, también se producen frutos deformes.

Para determinar el grosor promedio de la cascara de las naranjas, se utilizaron las mitades que previamente se habían utilizado para medir el diámetro. Con el apoyo del vernier digital, se midió el grosor de la cáscara de cada una de las cinco mitades para finalmente promediarlas. En el mercado, las naranjas sanas con la cáscara más delgada, tienen una mayor aceptación y valor comercial. Los frutos son preferidos con cáscaras

delgadas para poder retirarse fácilmente, sin llegar a extremos que pueden comprometer el tiempo de vida postcosecha (Ariza-Flores *et al.*, 2010) por lo tanto, se prefieren las cáscaras con valores de 5 mm que son considerados normales. El grosor de la naranja usualmente está en función de los nutrientes *N*, *K* y *Mg* la deficiencia puede provocar cáscaras finas y piel delgada, la deficiencia de *Ca* y *B* provocan cáscara áspera y gruesa, mientras que la deficiencia de *Mg* produce piel delgada (Molina, 2000).

El factor del sabor se obtuvo realizando pruebas de degustación, a sugerencia del productor se contactó a una persona que elabora algunos productos artesanales con la naranja. El artesano se encargó de degustar una muestra de cada una de las 325 naranjas y calificarlas en la escala de sabor de 1-5. Las naranjas más dulces se clasificaron entre 4 y 5, las desabridas entre 2 y 3 y las amargas se les asignó el valor de 1. El sabor es determinante para tener un buen mercado, dentro del estado de San Luis Potosí, las naranjas de esta región tienen un buen prestigio en lo que respecta a sabor y color. La deficiencia de *K* y *Mg* puede provocar frutos desabridos con bajos niveles de azúcar y acidez, además de un color opaco (Molina, 2000).

Finalmente, se obtuvo el número promedio de semillas por naranja, en la práctica parece un factor poco importante, de hecho, esta variedad de naranja se caracteriza por tener un número reducido de semillas. Por lo general los frutos con menos semillas son mejor aceptados por los consumidores (Ramos-Cruz *et al.*, 2023). Algunos trabajos han sugerido que el número de semillas se relaciona positivamente con la calidad de la fruta, es decir, un fruto con mayor número de semillas posee características de mejor calidad (Suárez-Espinosa, 2003).

El nutriente que determina en gran medida la producción total en una huerta es el *N*, también la deficiencia de *Zn* afecta directamente la producción y calidad del fruto debido a las afectaciones mayores que produce en las hojas, ya que la mayor absorción de este nutriente se da durante la floración y cuaje de los frutos, por lo tanto, una deficiencia en este periodo, puede provocar la caída de flores y por tanto reducir la producción total (Molina, 2000). Los árboles seleccionados para el muestreo de producción se identificaron con una etiqueta marcada con la clave de árbol, además, previo al primer corte de la temporada de cosecha, se realizó una campaña para marcar los árboles seleccionados con

una cinta distintiva (color azul) para que su localización fuera fácil durante el corte. Durante la cosecha, una cuadrilla realizó el conteo de los kilogramos obtenidos por árbol, para ello se asignó una persona encargada en cada surco en donde había árboles seleccionados para el muestreo. El recipiente de almacén (colote o canasto) en donde cada trabajador recolecta la naranja, tiene una capacidad de almacén de 42 kg, es un peso estándar debido a que es la forma en que miden el trabajo de los recolectores, a decir del jefe de la cuadrilla de los recolectores la variación en estos recipientes es de más menos 1 kg, por lo tanto se anotaron los colotes recaudados en los árboles muestreados y cuando el último colote no se llenó por completo, se pesaba en una báscula antes de vaciarse en el camión de carga. El segundo corte o cosecha se realizó en el mes noviembre repitiendo la misma metodología. Durante la primera cosecha se recolectaron 52 toneladas y en la segunda 9 toneladas, dando un total de 61 toneladas y un rendimiento promedio de 15.25 toneladas por hectárea en la temporada 2022.

Los compradores intermediarios toman en cuenta los factores medidos en esta investigación para la compra de la cosecha, el precio siempre está en función de la oferta y demanda, pero estos atributos también suelen ser importantes para fijar el precio de compra con el productor.

### **Adquisición de datos de muy alta resolución espacial**

La recolección de imágenes se realizó utilizando un UAV multirrotor Phantom 3 Pro de DJI Innovations (SZ DJI Technology Co., Shenzhen, Guangdong, China). Se realizó un vuelo planificado y ejecutado con las aplicaciones libres de Pix4Dcapture y DJI Go. Se utilizó un sensor MAPIR Survey 3W fabricado por la empresa MAPIR, el cual fue montado sobre el UAV. 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 a las 12:00 pm. Los vuelos se realizaron a una altura de vuelo de 120 m



con un traslape frontal de 85% y lateral de 75% a una velocidad de  $4 \text{ ms}^{-1}$ , con un tiempo de vuelo de 10 minutos. Después de adquirir la información multispectral a través del sensor Survery 3W se procesaron un total de 96 imágenes en formato JPG en el software Agisoft PhotoScan, para obtener un mosaico y así generar un archivo Geo TIF con tres bandas RG-NIR, alcanzando una resolución espacial de 5 cm. Para que la información obtenida pueda ser utilizada para diversos cálculos de índices de vegetación se realizó una corrección geométrica y una conversión de números digitales a números de reflectancia.

En el marco conceptual de la metodología NDVI basada en datos de percepción remota, en este estudio se obtuvo información del NDVI a nivel regional obtenidos con el sensor Landsat 7, de la fecha 25 de marzo de 2022 por ser la más cercana al vuelo del UAV utilizando el path 27 y row 45 de la nomenclatura del sensor mencionado. Estos datos espectrales se consultaron de la plataforma EEFlux (Earth Engine Evapotranspiration Flux) una versión de METRIC (Mapping Evapotranspiration at high Resolution with Internalized Calibration, por sus siglas en inglés) que funciona en el sistema Google Earth Engine. EEFlux ha sido desarrollado por el consorcio de la Universidad de Nebraska-Lincoln, el Instituto de Investigación del Desierto y la Universidad de Idaho con el apoyo financiero de Google. EEFlux procesa escenas individuales de Landsat de cualquier período desde 1984 hasta el presente y para casi todas las zonas terrestres del planeta (<http://eeflux-level1.appspot.com/>). La información del NDVI obtenido de las imágenes del sensor Landsat 7, se utilizó para validar los resultados de NDVI calculados con el sensor MAPIR, realizando una comparación de los valores promedio de ambos sensores.

### **Metodología Usada Para la Generación de las Zonas de Manejo**

Se muestrearon 65 árboles para obtener mapas de calidad de la fruta y producción, con el apoyo del software ArcGis (ArcGIS Versión 10.0. Environmental Systems Research Institute, Inc., 2010), se utilizaron herramientas de interpolación para generar los mapas de calidad de la fruta. La técnica seleccionada fue la ponderación de la distancia inversa (IDW, por sus siglas en inglés)

IDW estima valores de píxeles desconocidos a través de la combinación ponderada lineal de un conjunto de puntos (para este caso obtenidos del muestreo de los atributos de la fruta y producción), el ajuste de potencia y las barreras. Los resultados de salida brindan la proyección de mapas y superficies continuas generalmente en formato ráster que contiene información a nivel de píxel dentro del área de las barreras establecidas. Esta técnica parte del hecho de suponer que la variable representada cartográficamente disminuye su influencia a mayor distancia de su ubicación de muestra (Bartier y Keller, 1996). Los valores de salida para un píxel siempre se limitarán al rango de valores utilizados en la interpolación, es decir, que estos valores nunca serán mayores o inferiores a los datos de entrada. Además, entre más densa y mejor distribuida este la muestra de entrada, los resultados de IDW son más sólidos. La potencia controla la significancia de los puntos circundantes sobre el valor interpretado, entre más alto sea el valor de la potencia los resultados tendrán una influencia menor de los puntos más lejanos. Los valores de potencia son números reales mayores a cero, pero los valores razonables se encuentran entre 0.5 y 3, el valor predeterminado siempre es 2. Las barreras se utilizan para especificar el límite de la creación de la superficie raster de salida, normalmente se utilizan polígonos para delimitar estas barreras (Philip y Watson, 1982). Particularmente la herramienta IDW del software seleccionado tiene la capacidad trabajar hasta con 45 millones de puntos de entrada, después de esta cantidad los resultados pueden ser menos eficaces.

Las herramientas de interpolación más comunes son IDW y Kriging, para este trabajo se optó por utilizar el método de IDW. Este método asume que las predicciones son una combinación lineal de datos, como se muestra en la siguiente ecuación (1).

$$Z(S_0) = \sum_{i=1}^n \lambda_i Z(S_i) \quad i = 1, \dots, n \quad (1)$$

Donde  $Z(S_0)$  es el valor estimado en el punto interpolado  $S_0$ ,  $n$  es el número de observaciones vecinas usadas para la estimación y  $\lambda_i$  es el peso dado al valor observado  $Z(S_i)$  en las cercanías del valor  $S_0$  (Villatoro *et al.*, 2007). De esta manera se generaron 6

mapas de calidad y producción en formato raster utilizando las muestras levantadas en campo, lo que permitió estimar los valores de los 6 atributos en toda la huerta.

Los dos algoritmos más utilizados para el agrupamiento de factores son el K-medias y Fuzzy C-medias (Gavioli *et al.*, 2019). Se utilizó el algoritmo de agrupamiento no supervisado ISO clúster, para delimitar las zonas de manejo de acuerdo a las características más favorables de calidad y producción. El algoritmo ISO Clúster calcula la distancia euclidiana mínima cuando se asigna una muestra (píxel) candidato a clúster. En cada iteración el software asigna a los píxeles valores medios arbitrarios, los nuevos valores se recalculan para cada clúster en función de las distancias de cada píxel que pertenece al clúster después de la primera iteración. Este proceso es repetitivo, y en cada iteración el píxel se asigna al valor medio más cercano en el espacio de atributos multidimensional, de esta manera se calculan nuevos valores medios para cada clúster en función de la pertenencia de los píxeles de la iteración. Entre mayor sea el número de iteraciones se reduce la probabilidad de la migración de píxeles de un clúster a otro y a su vez cada clúster se vuelve más estable. El usuario asigna el número de clústeres, la cantidad mínima es de dos y no existe una cantidad máxima, pero entre más clústeres se necesiten, el algoritmo requiere realizar más iteraciones. A diferencia de la clasificación no supervisada que se encarga de asignar en grupos los objetos que pertenecen a clases predefinidas, la agrupación clúster no clasificada se enfoca en agrupar los objetos que presentan características similares, en este caso, varios objetos individuales de diferentes clases pueden ser parte de un mismo grupo. Iso Cluster se basa en la metodología de K-medias, trabajando con variables descriptivas continuas, algunas de las desventajas de K-medias es el hecho de no estimar el número de agrupamientos ideales y es el usuario quien dictamina el número ideal de grupos. Además, este método es altamente sensible a valores atípicos, por lo que se requiere detectar la posible presencia de valores atípicos y eliminarlos antes de iniciar a correr el programa, los grupos se calculan de la siguiente manera:

$$J = \sum_{i=1}^p \sum_{j=1}^k (||x_i - S_j||)^2 p_x \quad (2)$$

Donde  $k$  es el número de clústeres,  $p$  es el número de objetos,  $x$  son los objetos y  $S_j$  es el centroide del clúster. Con un número de clústeres demasiado pequeño, la función objetivo será grande (Eshimiakhe *et al.*, 2023). Por otro lado, la función objetivo es cero cuando el número de clústeres es igual al número de datos. En este trabajo se trabajaron 3 clústeres que finalmente se convierten en las zonas de manejo. El número de zonas fue asignado de acuerdo a lo platicado con el productor, y que entre más zonas se generen aumenta la dificultad de llevar a cabo un buen manejo real en campo. De esta manera se generaron seis mapas de calidad y producción de la fruta con una función objetivo normal, divididos en tres grupos de acuerdo a sus características, quedando en un grupo las mejores condiciones de cada variable, en otro grupo las condiciones medias de cada variable y finalmente en el último grupo las condiciones más desfavorables.

### **Generación de Índices de Vegetación (NDVI)**

Los índices de vegetación se calculan a partir de imágenes, las más utilizadas son las obtenidas por medio de satélites, en la actualidad el uso de imágenes obtenidas por medio de UAV's se ha hecho más común y también son utilizadas para calcular índices de vegetación a escalas más pequeñas por ejemplo al nivel de huerta. En particular el índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) (Rouse *et al.*, 1973) es uno de los más usados en el mundo ya que mide de manera confiable la cantidad, calidad y desarrollo de la vegetación, se mide en una escala de “-1” a “1”, donde los valores más cercanos a “1” indican una vegetación más sana y vigorosa. En sentido, se puede intuir que los árboles de naranja que presentan mejores valores de NDVI tienen una mejor producción en cuanto a calidad y producción. El NDVI fue calculado para toda el área y se extrajo el valor promedio de cada árbol, posteriormente estos valores validaron los resultados de las zonas de manejo.

Los índices de vegetación se derivan de las bandas de reflectancia basadas en el espectro visible perteneciente al RGB (Rojo, Verde, Azul) y el IR (Infrarrojo), además de otras regiones del espectro electromagnético más estrechas. La obtención de datos de las bandas RGB aportan gran cantidad de información del estado fisiológico de la vegetación, regularmente estas bandas espectrales son captadas por una cámara convencional, sin

embargo, para obtener índices de vegetación que puedan captar el cambio de pigmento en las plantas, se utilizan cámaras multiespectrales e hiperespectrales. El NDVI es calculado a partir de los espectros rojo e infrarrojo, debido a la elevada reflectividad en el espectro del infrarrojo detecta el contenido de clorofila relacionado directamente al estado vegetativo. Este índice es robusto y es comúnmente usado por la sencillez de su obtención y la interpretación, ya que minimiza el efecto del ruido ocasionado por el suelo, la atmósfera, el ángulo y posición tanto del sensor como del sol (Rouse *et al.*, 1973). Para este trabajo se utilizaron datos del sensor multiespectral MAPIR survey 3W y del sensor Landsat 7, el NDVI se calculó mediante la siguiente expresión matemática:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (3)$$

Donde,  $\rho_{NIR}$  = reflectancia en la banda infrarrojo cercano y  $\rho_{Red}$  = reflectancia en la banda Rojo.

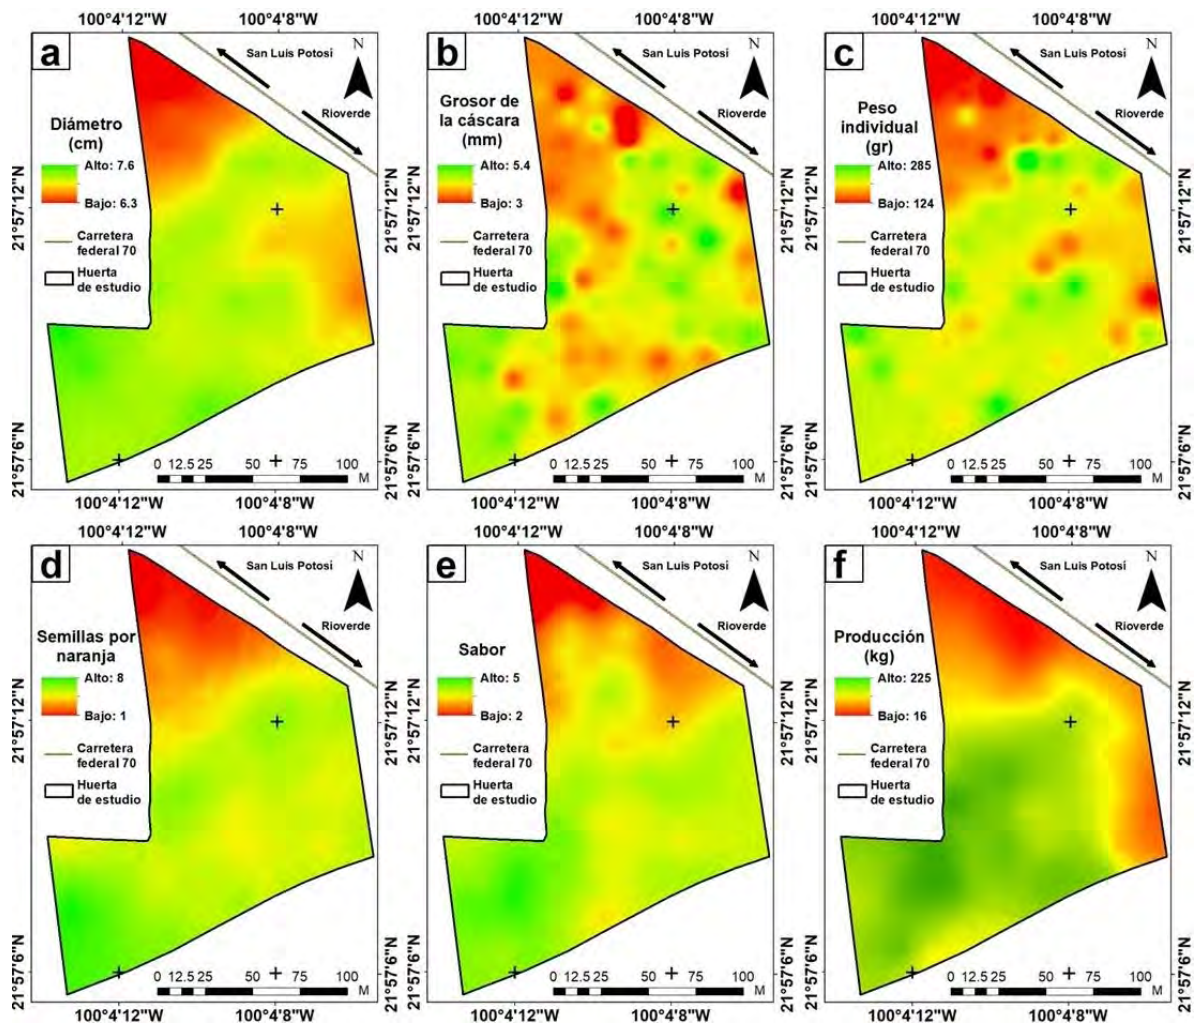
Posteriormente se calculó el NDVI de las imágenes Landsat 7 obtenidas de la plataforma EEFlux utilizando el path 27 y row 45. El NDVI calculado para las imágenes del sensor Landsat 7 se utilizaron para validar los resultados obtenidos del sensor MAPIR, los cuales fueron utilizados para compararse con la calidad y producción de cada árbol.

## RESULTADOS

### Mapas de Calidad y Producción de Naranja

Con los datos obtenidos del muestreo se pudo identificar variabilidad en producción y calidad de la fruta, a partir de técnicas geoestadísticas de interpolación, puntualmente con la técnica de IDW, el panel de mapas se muestra en la Figura 4. Se midieron algunos factores que influyen directamente en la calidad y venta de la naranja de la variedad Valencia de esta región. Los mapas generados brindan un panorama amplio de las zonas dentro de la huerta que tienen las mejores condiciones para cada uno de los atributos que se midieron en campo. De acuerdo a los resultados, las naranjas más grandes se encuentran la parte suroeste de la huerta, las naranjas con la cáscara más gruesa y más pesadas en la

zona centro y suroeste, las naranjas con el mejor sabor y más semillas presentan la misma tendencia en la zona suroeste de la huerta, los árboles más productivos se localizan en las zonas centro, oeste y suroeste de la huerta. Se puede observar que las zonas que presentan menos calidad y rendimiento más bajo se localizan en la parte norte y este de la huerta. Es de recalcar que la parte central de la huerta es también la frontera entre la zona de mejor calidad y de peor calidad y rendimiento.



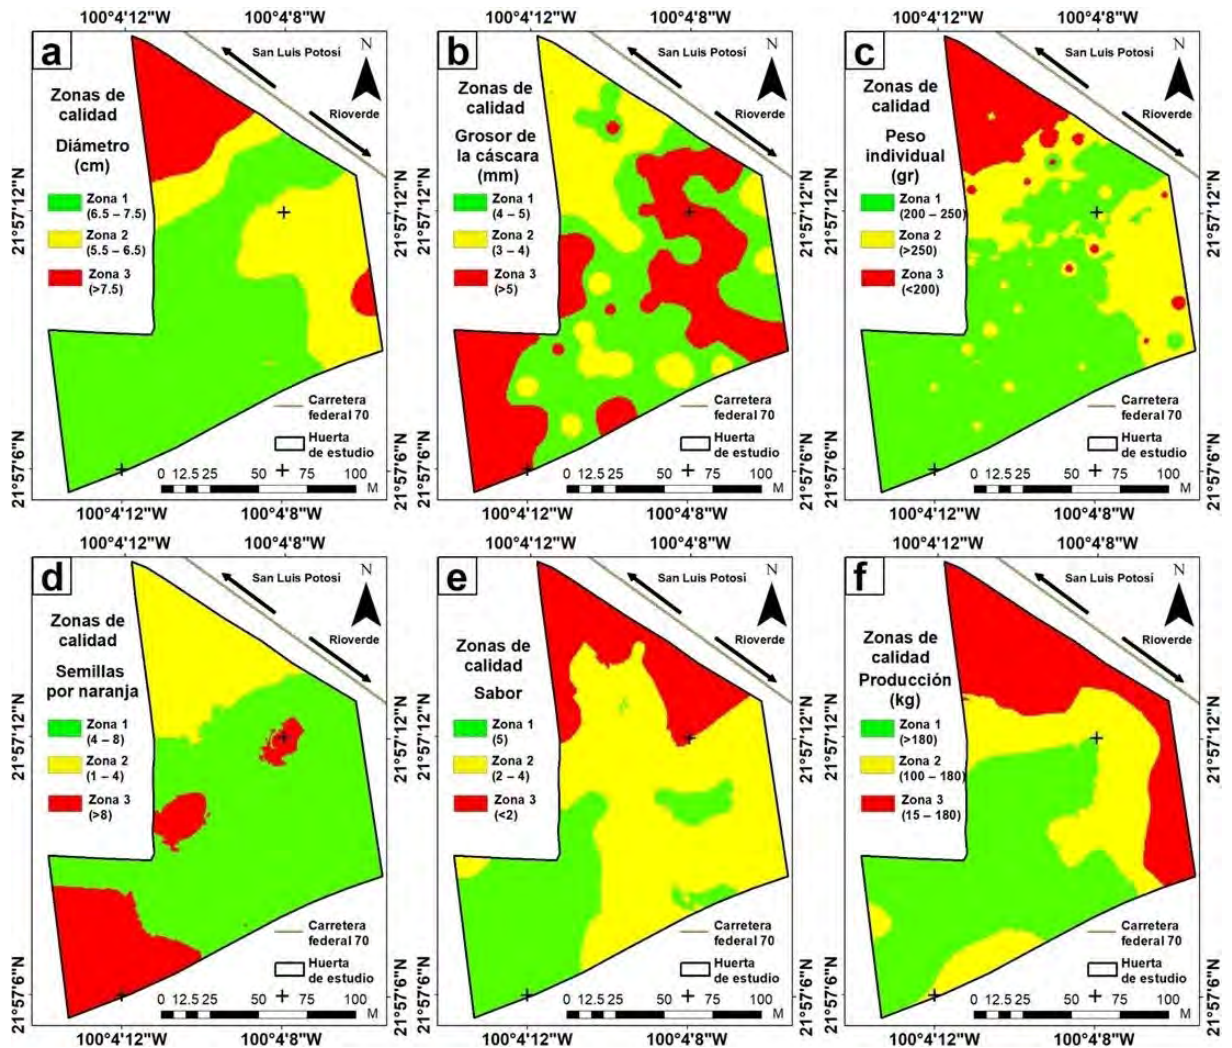
**Figura 4.** Panel de mapas de calidad de la fruta: a) diámetro, b) grosor de la cáscara, c) peso individual, d) semillas por naranja, e) sabor y f) producción.

En este sentido, se podría decir que la calidad de la fruta y rendimiento para esta huerta en particular se rige en una dirección de suroeste (mejores condiciones de calidad de rendimiento) a noreste (condiciones menos favorables de calidad y rendimiento). Con base en lo observado en campo la salud de los árboles también se rige por esta misma tendencia, teniendo los árboles más sanos en la parte suroeste y los árboles más enfermos en la porción noreste y este.

### **Delimitación de las Zonas de Manejo**

Los resultados preliminares muestran zonas con aptitudes de baja, media y alta calidad, de acuerdo a lo observado en campo, se puede decir que corresponden a la realidad que se percibió durante los recorridos por la huerta. De manera visual se detectaron tres zonas bien definidas en función de la salud de los árboles que posteriormente se confirmaron con los factores de calidad y producción obtenidos para esta investigación. Otras investigaciones también han sugerido tres zonas para un mejor manejo (Yari *et al.*, 2017). En este sentido, se propusieron tres clústeres para cada variable que fueron generados en el software ArcGis (ArcGIS Versión 10.0. Environmental Systems Research Institute, Inc., 2010). En primera instancia, se calcularon las zonas de manejo de manera individual para cada factor (Figura 5). De manera general el algoritmo agrupa dentro de cada uno de los clústeres, los factores que presentan más similitudes entre sí y a la vez más diferencias respecto a los otros clústeres.

Las zonas de manejo generadas permiten visualizar de manera más clara cuales son las zonas con mejores atributos y las zonas más deficientes, confirmando que los factores muestran una tendencia dónde la calidad más alta se encuentra en la parte suroeste de la huerta y la calidad disminuye en dirección a la parte noreste y este de la huerta. La tendencia es muy clara en 4 de las 6 variables, exceptuando las variables de grosor de cáscara y semillas por naranja, en las que se puede observar que en la parte suroeste presentan baja calidad.

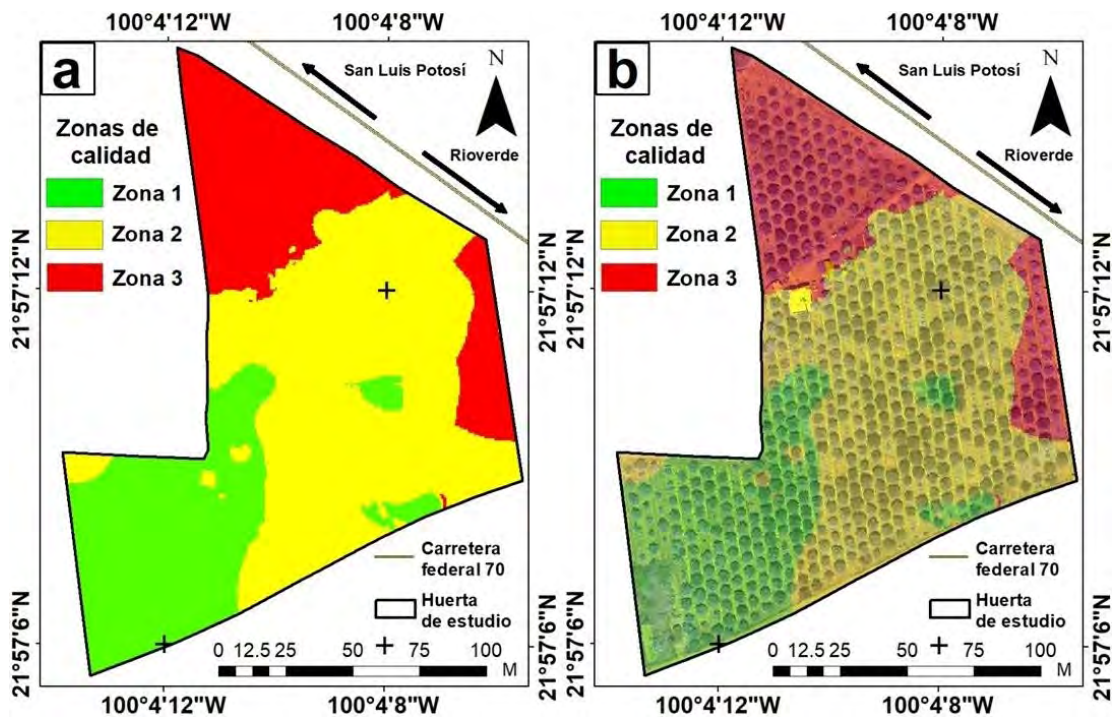


**Figura 5.** Zonas de calidad de la fruta para cada variable: a) diámetro, b) grosor de la cáscara, c) peso individual, d) semillas, e) sabor y f) producción.

Siguiendo la misma metodología aplicada a cada variable, las zonas de manejo correspondientes a la huerta fueron calculadas a partir de los mapas obtenidos de cada variable individual. Se identificaron tres zonas de calidad y producción, zona 1 (ZM1), zona 2 (ZM2) y zona 3 (ZM3) (Figura 6a). La capa generada se sobrepuso en el ortomosaico de la huerta, para apreciar de mejor manera los límites sobre los árboles (Figura 6b). La ZM1 obtuvo un área de  $10526.13 \text{ m}^2$ , la ZM2 un área de  $19842.34 \text{ m}^2$  y la zona de manejo ZM3 un área de  $9359.89 \text{ m}^2$ . De acuerdo a la calidad de la fruta específica para esta región la ZM1 es la que tiene las mejores características de calidad y



condiciones para la venta, la ZM2 tiene características de mediana calidad y la ZM3 tiene las condiciones más desfavorables.



**Figura 6.** a) Mapa general de zonas de calidad de la fruta y b) Capa de zonas calidad de la fruta montado sobre la huerta de estudio.

Dentro de la ZM3 se encuentran 124 árboles, la ZM2 contiene 319 y la mejor zona (ZM1) 149 árboles. En la huerta predominan los árboles con condiciones de calidad media, coincidiendo con los datos recabados en campo. En este sentido, se realizó un cálculo del rendimiento promedio por árbol para cada zona de manejo. Los resultados fueron los siguientes: 164 kg por árbol para la ZM1, 133 kg por árbol para la ZM2 y 47 kg por árbol para la ZM3. La diferencia de producción para cada zona es muy elevada, la producción de la ZM2 es tres veces mayor que la producción de la ZM3, mientras que la producción de la ZM1, es 3.5 veces mayor que la producción de la ZM3. Por otro lado, la producción de la ZM1 es de 30 kg por árbol mayor que la ZM2. De acuerdo a la estadística, la producción de la ZM3 representa el 8% de la producción total, la ZM2 el 58% (tomando

en cuenta que es la zona con más árboles) y la ZM1 el 34% a pesar de que cuenta con poco menos de la mitad de árboles que la ZM2.

### Relación del NDVI con la Calidad en las Zonas de Manejo

Algunos investigadores han relacionado el NDVI con el rendimiento y calidad de fruta (He *et al.*, 2022). En este sentido, se generó la capa raster de NDVI con la información obtenida del sensor MAPIR, posteriormente se generó este mismo índice con una imagen Landsat con la fecha más cercana a la fecha de del vuelo con el UAV, con el fin de evaluar la consistencia de los valores obtenidos con el producto del sensor MAPIR, posteriormente se compararon los resultados. Se calculó el NDVI promedio para cada zona de manejo con ambos recursos, también se calculó el NDVI, excluyendo los valores menores de 0.3, (Jaramillo-Véliz *et al.*, 2021) con la intención de desprestigiar el suelo desnudo y elementos que puedan generar ruido en cálculo de los promedios, de esta manera se trabajó únicamente información de la copa de los árboles (Cuadro 1).


**Cuadro 1.** Valores del NDVI general promedio y NDVI promedio calculado con valores mayores de 0.3.

	Promedio NDVI general		
	ZM1	ZM2	ZM3
UAV	0.44	0.40	0.32
Landsat	0.46	0.46	0.38
	Promedio NDVI general a partir de valores de 0.3		
	ZM1	ZM2	ZM3
UAV	0.46	0.42	0.41
Landsat	0.45	0.45	0.38

Los resultados de la escena Landsat mostraron consistencia con los resultados del sensor MAPIR. Los índices obtenidos de la imagen Landsat se mantienen constantes tanto para el promedio general como para el promedio que excluye valores por debajo de 0.3 de NDVI, mientras que los valores de NDVI obtenidos con las imágenes del sensor MAPIR, muestran una diferencia notable entre el valor calculado con el promedio general y con valores superiores a 0.3. Aunque los resultados de NDVI son muy similares entre la ZM1

y la ZM2, de acuerdo a la información recolectada en campo, los factores de calidad y producción son mejores en la ZM1.

El inventario general del total de los árboles de la huerta, fue reclasificado con los valores de NDVI superiores a 0.3 obtenidos con el UAV (Figura 7). De esta manera, el inventario se nutre con información de rendimiento promedio, información de calidad de la fruta y el índice de vegetación que refleja el estado de salud de los árboles. Por lo tanto, se pueden enfocar esfuerzos y decisiones informadas para mejorar el rendimiento de la producción. Se puede estimar que, si la ZM2 y la ZM3 logran los índices productivos de la ZM1, la huerta tendría el potencial de aumentar en un 33% el rendimiento general.



**Figura 7.** Reclasificación del inventario general de la huerta con los valores de NDVI promedio mayores a 0.3 obtenido con el sensor MAPIR.

## **DISCUSIÓN**

### **Características Ideales Para la Naranja en la Región Productora**

Las características ideales para la venta de la naranja varían de acuerdo a las necesidades del mercado objetivo, además, las características de calidad y producción son diferentes en cada región productora. En este sentido, se realizó una encuesta a 50 productores de la región para saber cuáles son los parámetros ideales de cada factor medido en este trabajo para la venta de la naranja. La mayoría de los productores coincide en que, es mejor una naranja de dimensiones medianas. El grosor de cascara ideal, es delgada sin que sea menor a los 3 mm, ni mayor a los 6 mm, las naranjas más atractivas de acuerdo a su peso deberían de rondar los 200 gr., la mayoría de los productores coincide en que la naranja ideal debe de tener entre 4 y 7 semillas. En cuanto a sabor, se prefiere que sea tan dulce como sea posible y finalmente todos los productores desean que sus árboles rindan el mayor número de kilogramos posible, de acuerdo a los resultados de la encuesta, en la actualidad los árboles en esta región producen en promedio 150 kg por árbol. En la actualidad es complicado que las huertas tengan una producción homogénea con las características ideales declaradas por los productores, la variabilidad espacial y los problemas de salud de los árboles dificultan tener una producción de alta calidad. En general tener una calidad baja en la producción de naranja puede comprometer el precio y por ende las ganancias de los productores. Esta situación a su vez provoca cierto grado de incertidumbre entre quienes se dedican a esta actividad y algunos productores han decidido abandonar la producción de naranja.

### **Determinación del Número de Zonas de Manejo**

Se trabajó con seis factores, incluyendo el rendimiento de producción, la literatura indica que no hay un número indicado de capas de información para delimitar las zonas de manejo, incluso tampoco hay un número ideal de zonas de manejo. Es común que se piense que entre más capas de información se utilicen, mayor precisión tendrán los polígonos generados, sin embargo, incluir más capas de datos en el proceso de delineación de zonas de manejo no necesariamente garantiza una mejor precisión de la técnica,

algunos estudios han demostrado que el método con menos capas de información es tan preciso como el método con más capas (Yari *et al.*, 2017; Georgi *et al.*, 2018). Es importante tener en cuenta la información disponible para generar las zonas de manejo, pero también el contexto de la posible aplicación, en general, se proponen entre 3 y 5 zonas de manejo (Fridgen *et al.*, 2004; Yan *et al.*, 2007; Gavioli *et al.*, 2016; Yari *et al.*, 2017; De Assis Silva *et al.*, 2022; Mojtaba *et al.*, 2022), independientemente del método e información con el que se generen las zonas de manejo. En este sentido, se optó por generar tres zonas de manejo, además, de acuerdo a las charlas con el productor, a partir de más de tres zonas de manejo sería más complejo la administración de las mismas.

### **Relación del NDVI con la Calidad y Producción**

Información como el NDVI, brindó más certidumbre a los resultados de las ZM, ya que las zonas de mejor calidad y mayor producción se relacionan con un valor promedio más alto de NDVI. Algunos investigadores han relacionado el NDVI con las zonas de manejo y la producción de los cultivos (Mirhaji *et al.*, 2021; Shammi y Quingmin, 2021; Marino, 2023). Se trabajó con imágenes multiespectrales de muy alta precisión, obtenidas con un sensor multiespectral a bordo de un UAV, por lo cual se obtuvieron índices de alta precisión. Los resultados fueron comparados con los índices generados a partir de una imagen Landsat 8, que se relacionaron estrechamente con los resultados de las imágenes captadas por el sensor MAPIR, a pesar de la gran diferencia de resolución espacial entre ambos sensores. Se apreció una leve variación de los resultados de NDVI entre ambos sensores, aun así, resultados indican que los sensores coinciden en que las zonas con mejores índices de vegetación corresponden a las zonas de mayor calidad y producción. Este resultado brinda un panorama de acción inicial para homogenizar la producción, tal parece que, la primera acción a llevar a cabo es mejorar la salud de los árboles de la ZM2 y ZM3. Para ello, vale la pena explorar los factores que mantienen en desventaja a estos árboles con respecto a la ZM1. Lograr homogenizar la producción implica un potencial de mejora de hasta un 33% lo que sin duda aumentaría notablemente las ganancias del productor.

## **Factores Externos que Influyen en la Producción**

Las plagas y enfermedades han influido negativamente en la producción, incluso, el cambio de técnica de riego que se vivió en la región en los últimos años (riego rodado por microaspersión) así como el cambio climático, podrían estar influyendo en la disminución de hasta el 70% de la producción en la huerta de estudio y en la región en los últimos años. Se observa que los árboles que se encuentran en los límites perimetrales de la huerta de estudio tienen una calidad y rendimiento más bajos, puntualmente aquellos que colindan con los caminos circundantes a la huerta, la ZM3 es la zona más expuesta al tráfico vehicular, en general todos los árboles mantienen condiciones similares de acceso al agua, nutrientes y productos aplicados para plagas y enfermedades. Sin embargo, estos árboles tienen la particularidad de estar expuestos al polvo que se genera debido al tráfico en los caminos, como dato a considerar, la parcela colinda en el lado norte primero con un camino de terracería y después con una carretera federal que mantiene tráfico constante en donde el escape de los vehículos es un productor de polvo (Farmer, 1993).

Es notoria la acumulación del polvo en hojas, lo cual puede afectar la fotosíntesis, la respiración, la transpiración y permitir la penetración de contaminantes gaseosos fitotóxicos (Farmer, 1993), la reducción del crecimiento (Sharifi *et al.*, 1997) a través del efecto sobre el intercambio de gases foliares (Ernest, 1982). Las partículas de polvo pueden ocluir las estomas (Ricks y Williams, 1974), y aumentar la temperatura de las hojas al absorber radiación excesiva (Hirano *et al.*, 1995).

La zona de producción se caracteriza por estar sobre arenas, las micropartículas de la arena pueden provocar un efecto lupa, aumentando la temperatura en la hoja y mantener en estrés constante a los árboles. Por otro lado, estudios como el de Yan *et al.* (2011) sostienen que el polvo eólico puede ser un importante aportador de nutrientes. En cítricos, el polvo se puede considerar como estrés abiótico, afectando negativamente en las hojas, tallos y raíces, el contenido de micronutrientes también se ve afectado, lo que eventualmente repercute en la producción (Abbas *et al.*, 2023).

Particularmente para cítricos se han reportado efectos como reducción del crecimiento, cuajado de frutos, lesiones foliares y defoliación parcial (Farmer, 1993). Los trabajos del efecto del polvo en cítricos son limitados, sin embargo, en otras especies se han encontrado resultados contundentes de la afectación del polvo en árboles frutales. Naidoo

& Chirkoot (2004) analizaron el efecto que produce el polvo producido por el carbón en la especie de manglar *Avicennia marina (Forssk) Vierh.* para ello realizaron un muestreo del rendimiento fotosintético en árboles. De acuerdo a sus resultados, el polvo de carbón redujo significativamente el intercambio de dióxido de carbono de las superficies en las hojas entre un 17 y un 39%. Concluyen que, los árboles que se encuentran más cerca de las fuentes de polvo tienen peor salud que los que se encuentran más lejos. Además, el polvo también cubre la superficie del suelo provocando efectos negativos en las raíces. Los antecedentes sugieren que el estrés en los árboles derivado del polvo podría estar influyendo negativamente la calidad y producción del fruto, esta situación da pauta a la generación de un estudio que confirme o descarte este problema, lo cual sería de gran interés en la región, ya que muchas huertas tienen una condición de ubicación similar a la huerta de estudio.

### **Nutrición y Calidad del Suelo**

Es indispensable tener un adecuado inventario de árboles ya que además de poder identificar cada árbol dentro de la huerta, ayuda como soporte en la delimitación de las zonas de manejo. Además, los resultados obtenidos pueden generar más información para el inventario, con lo cual se puede dar un seguimiento específico y generar una base de datos histórica para monitorear la evolución a nivel de árbol.

Es evidente que además de plagas y enfermedades, la nutrición pueda ser otro factor a considerar dentro de las causas de la heterogeneidad que existe en la huerta. La ZM3 es la más ineficiente, debido a su baja productividad se puede suponer que tuvo deficiencias de *N* y *K*, aunque debido a la baja calidad de los frutos generados en esta zona, también es probable que tenga déficit de micronutrientes como el *Ca*, *Mn*, *B* y *Fe*. Sin embargo, el hecho de que las ZM1 y ZM2 tengan mejores números, no significa que estén exentas de tener deficiencias nutrimentales. Será importante detectar las deficiencias por zona para saber si una mejor aplicación de fertilizantes puede mejorar las condiciones actuales de la huerta.

Un estudio de suelos estuvo fuera de los objetivos de investigación, si bien son los parámetros más utilizados para definir zonas de manejo (Córdoba *et al.*, 2016) este trabajo

pretendió llevar a cabo esta metodología de la manera más económica posible. No obstante, un estudio de suelos es fundamental para ofrecer al productor recomendaciones más certeras. Los mapas de zonas de manejo pueden perfeccionarse y mejorarse añadiendo diferentes tipos de métodos y datos, siempre que sea necesario (Breunig *et al.*, 2020). La ventaja de contar con las ZM, es que un análisis de suelos y de nutrición puede acotarse a las necesidades por zona, haciendo más eficiente los resultados específicos para la huerta productora.

## CONCLUSIONES

La metodología utilizada en esta investigación resulta prometedora en cuanto a la administración en huertas de cítricos se refiere, teniendo en cuenta que es económica puede ayudar de gran manera a los productores a optimizar su producción atendiendo a las necesidades a nivel de árbol y tomando decisiones informadas.

Los UAV juegan un rol importante en este tipo de investigaciones ya que se pueden generar índices espectrales e inventarios a un bajo costo, lo cual puede resultar atractivo para los productores y de esta manera promover el uso de la agricultura de precisión.

El NDVI puede brindar un panorama general del estado de salud de los árboles, lo cual es importante porque en función de ello, se rige la producción y la calidad de la naranja.

Los mapas de calidad y producción brindan información valiosa para los productores, ya que en una primera instancia se pueden distinguir y delimitar los árboles que están teniendo los rendimientos más pobres y en los cuales el productor debería de enfocar los primeros esfuerzos para lograr aumentar el rendimiento. Por otro lado, los mapas también son muy valiosos para los productores porque pueden planificar la cosecha, ya que los tiempos de corte entre las mejores zonas y las zonas más deficientes pueden variar notablemente, incluso de acuerdo a los resultados del rendimiento promedio de puede un cálculo aproximado del rendimiento por cada zona para la siguiente temporada de producción. Los compradores también echar mano de esta información para planificar la logística de la compra y cosecha.



Esta investigación forma parte de un sistema más complejo mediante el cual se puedan actualizar año con año las zonas de manejo dentro de la huerta, ya que se generaron en función de la calidad de la fruta y por ende influyó el estado de salud de los árboles. Estos parámetros pueden tener cambios dinámicos en poco tiempo, como la caída o derribamiento de árboles enfermos, el inicio de la producción de árboles jóvenes, la plantación de nuevos árboles, las plagas y enfermedades y por supuesto condiciones climáticas, como la precipitación. Para lograr resultados contundentes, será necesario actualizar las zonas de manejo cada ciclo de cosecha.

## LITERATURA CITADA

- Abbas, T., Ahmad, I., Nawaz, R., Nazim, M., Gatasheh, M.K., Alamri, A.M. and Muneeb, A. (2023). Physiological responses and antioxidant properties of *Citrus reticulata* under different abiotic stresses mitigated by endogenous melatonin. *Scientia Horticulturae*, 322(1), 112442.
- Anderson, C.M. (1996). Manual para productores de naranja y mandarina de la región del Río Uruguay. *INTA, Estación Experimental Agropecuaria Concordia*. <https://bit.ly/3TdN9uu>.
- Ariza-Flores, R., Tejacal, I.A., Beltrán, M.N., Ambriz- Cervantes, R., Lugo-Alonso, A., Barrios-Ayala, A. y Barbosa-Moreno, F. (2010). Calidad de los frutos de naranja 'Valencia' en Morelos, México. *Revista Iberoamericana de tecnología postcosecha*, 11(2), 148–153.
- Bartier, P.M. and Keller, C.P. (1996). Multivariate interpolation to incorporate thematic surface data using inverse distance weighting (IDW). *Computers & Geosciences*, 22 (7), 795–799.
- Benny, N., Shams, R., Dash, K.K., Pandey, V.K. and Bashir, O. (2023). Recent trends in utilization of citrus fruits in production of eco-enzyme. *Journal of Agriculture and Food Research*, 13, 100657.
- Breunig, F.M., Soares-Galvao, L., Dalagnol, R., Dauve, C.E., Parraga, A., Santi, A.L., Della-Flora, D.P. and Chen, S. (2020). Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. *International Journal of Applied Earth Observation and Geoinformation*, 85, 102004. <https://doi.org/10.1016/j.jag.2019.102004>.

- Cavaco, A.M., Antunes, M.D., Guerra, R., Rosendo, M., Pires, R., Brázio, A., Silva, L., Alfonso, A.M., and Panagopoulos, T. (2018). Fruit quality survey techniques to optimize crop management in citrus orchards. *Acta horticulturae*, 1194, 135–142.
- Chen, F., Cui, N., Jiang, S., Wang, Z., Li, H., Lv, M., Wang, Y., Gong, D. and Zhao, L. (2023). Multi-objective deficit drip irrigation optimization of citrus yield, fruit quality and water use efficiency using NSGA-II in seasonal arid area of Southwest China. *Agricultural Water Management*, 287, 108440.
- Colaço, A.F., Molin, J.P., Rosell-Polo, J.R., Escolà, A. (2019). Spatial variability in commercial orange groves. Part 2: relating canopy geometry to soil attributes and historical yield. *Precision Agriculture*, 20, 805–822.
- Córdoba, M.A., Bruno, C.I., Costa, J.L., Peralta, N.R., and Balzarini, M.G. (2016). Protocol for multivariate homogeneous zone delineation in precision agriculture. *Biosystems Engineering*, 143, 95–107.
- De Assis Silva, S., Dos Santos, R.O., De Queiroz, D.M., Soares de Souza Lima, J., Pajehú, L.F. and Carvalho Medauar, C. (2022). Apparent soil electrical conductivity in the delineation of management zones for cocoa cultivation. *Information Processing in Agriculture*, 9(1), 443–455. <https://doi.org/10.1016/j.inpa.2021.04.004>.
- Ernest, W.H.O. (1981). Monitoring of particulate pollutants. In: Steubing, L., Jager, H.-J. (Eds.), *Monitoring of Air Pollutants by Plants: Methods and Problems*, 1981. (Eds.). *Proceedings of the International Workshop*, Osnabriick (F.R.G.), September 24–25. Dr W Junk Publishers, The Hague.
- Eshimiakhe, D., Jimoh, R., Suleiman, M. and Lawal, K. (2023). Improved cluster analysis of Werner solutions for geologic depth estimation using unsupervised machine learning. *Kuwait Journal of Science*, 100144.
- Ezrari, S., Radouane, N., Thiri, A., El Housni, Z., Mokri, F., Özer, G., Lazraq, A., Belabess, Z., Amiri, S. and Lahlali, R. (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.pmpp.2021.101753>.
- Farmer, A.M. (1993). The effects of dust on vegetation—a review. *Environmental Pollution*, 79(1), 63-75.
- Fridgen, J. J., Kitchen, N. R., Sudduth, K. A., Drummond, S. T., Wiebold, W. J. and Fraisse, C. W. (2004). Management zone analyst. *Agronomy Journal*, 96(1), 100–108.
- Gavioli, A., De Souza, E.G., Bazzi, C.L., Guedes, L.P.C. and Schenatto, K. (2016). Optimization of management zone delineation by using spatial principal

- components. *Computers and Electronics in Agriculture*, 127, 302–310. <https://doi.org/10.1016/j.compag.2016.06.029>.
- Gavioli, A., De Souza, E.G., Bazzi, C.L., Schenatto, K. and Betzek, N.M. (2019). Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. *Biosystems Engineering*, 181, 86–102. <https://doi.org/10.1016/j.biosystemseng.2019.02.019>.
- Georgi, C., Spengler, D., Itzerott, S. and Kleinschmit, B. (2018). Automatic delineation algorithm for site-specific management zones based on satellite remote sensing data. *Precision Agriculture*, 19, 684–707. <https://doi.org/10.1007/s11119-017-9549-y>.
- He, L., Fang, W., Zhao, G., Wu, Z., Fu, L., Li, R., Majeed, Y. and Dhupia, J. (2022). Fruit yield prediction and estimation in orchards: A state-of-the-art comprehensive review for both direct and indirect methods. *Computers and Electronics in Agriculture*, 195, 106812.
- Hirano, T., Kiyota, M. and Aiga, I. (1995). Physical effects of dust on leaf physiology of cucumber and kidney bean plants. *Environmental Pollution*, 89, 255–261.
- Jaramillo-Véliz, J.J., Quimis-Gómez, A.J. y Gómez-Bailón, S.P. (2021). Análisis del cambio espacio-temporal en la cobertura vegetal del cerro de hojas Jaboncillo durante el periodo 2015-2020. *Polo del conocimiento*, 57 (6)4, 632–652.
- Li, Y., Shi, Z., Wu, C. F., Li, H. Y., and Li, F. (2008). Determination of potential management zones from soil electrical conductivity, yield and crop data. *Journal of Zhejiang University Science B*, 9(1), 68–76. <https://doi:10.1631/jzus.B071379>.
- Marino, S. (2023). Understanding the spatio-temporal behaviour of the sunflower crop for subfield areas delineation using Sentinel-2 NDVI time-series images in an organic farming system. *Heliyon*, 9(9), e19507.
- Mirhaji, H., Soleymani, M., Asakereh, A. and Mehdizadeh, S.A. (2021). Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions. *Computers and Electronics in Agriculture*, 191, 106533.
- Mojtaba Zeraatpisheh, M., Bottega E.L., Bakhshandeh, E., Owliaie, H.R., Taghizadeh-Mehrjardi, R., Ruth, K., Scholten, T. and Xu, M. (2022). Spatial variability of soil quality within management zones: Homogeneity and purity of delineated zones. *CATENA*, 105835.
- Molina, E. (2000). Fertilización y nutrición de naranja en Costa Rica. *XI Congreso Nacional Agronómico/III Congreso Nacional de Suelos 1999. Conferencia 84*. Accessed: Aug 24, 2021. Available at: <https://bit.ly/3moYPMu>

- Moriya, É. A. S., Imai, N. N., Tommaselli, A. M. G., Berveglieri, A., Santos, G. H., Soares, M. A., Marino, M., and 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>.
- Naidoo, G. and Chirkoot, D. (2004). The effects of coal dust on photosynthetic performance of the mangrove, *Avicennia marina* in Richards Bay, South Africa. *Environmental Pollution*, 127(3), 359–366.
- Philip, G. M. and D. F. Watson. (1982). A Precise Method for Determining Contoured Surfaces. *Australian Petroleum Exploration Association Journal*, 22, 205–212.
- Ramos-Cruz, C.M., Pérez-Evangelista, E.R., Martínez-Medina, J., Acosta-Díaz, E. y Almeyda-León. I.H. (2023). Calidad de frutos de cultivares de naranja temprana en Nuevo León. *Revista mexicana de ciencias agrícolas*, 14(1), 75–84.
- Ricks, G.R. and Williams, R.J.H. (1974). Effects of atmospheric pollution on deciduous woodland part 2: effects of particulate matter upon stomatal diffusion resistance in leaves of *Quercus petraea* (Mattuschka) Leibl. *Environmental Pollution*, 6, 87–109.
- Riolo, M., Moreno-Villena, A., Calpe, J., Luz, C., Meca, G., Tuccitto, N. and Cacciola, S.O. (2024). A circular economy approach: A new formulation based on a lemon peel medium activated with lactobacilli for sustainable control of post-harvest fungal rots in fresh citrus fruit. *Biological Control*, 105443.
- Rouse, J.W., Haas, R.H., Schell, J.A. and Deering, D.W. (1973) Monitoring Vegetation Systems in the Great Plains with ERTS (Earth Resources Technology Satellite). *Proceedings of 3rd Earth Resources Technology Satellite Symposium, Greenbelt*, 10-14 December, SP-351, 309–317.
- Shammi, S.A. and Quingmin, M. (2021). Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. *Ecological Indicators*, 121, 107124. <https://doi.org/10.1016/j.ecolind.2020.107124>.
- Sharifi, M.R., Gibson, A.C. and Rundel, P.W. (1997). Surface dust impacts on gas exchange in Mojave Desert shrubs. *Journal of Applied Ecology*, 34, 837–846.
- Spreen, T. H., Gao, Z., Fernandes, W. and Zansler, M. L. (2020). Global economics and marketing of citrus products. *The Genus Citrus*, 471–493. <https://doi:10.1016/b978-0-12-812163-4.00023-1>.
- Suárez-Espinosa, C. (2003). Relación entre la calidad del fruto y el número de semillas en papaya (*Carica papaya* L.). Tesis de maestría. *Universidad Autónoma de Chapingo*, 61 pgs.

- Villatoro, M., Henríquez, C. y Sancho, F. (2007). Comparación de los interpoladores IDW y Kriging en la variación espacial de pH, Ca, CICE y P del suelo. *Agronomía Costarricense*, 32(1), 95-105.
- Wang, N., Xu, D., Xue, J., Zhang, X., Hong, Y., Peng, J., Li, H., Mouazen, A.M., He, Y. and Shi, Z. (2023). Delineation and optimization of cotton farmland management zone based on time series of soil-crop properties at landscape scale in south Xinjiang, China. *Soil and Tillage Research*, 231, 105744.
- Xu, C., Alhejaili, W., Saifullah, S., Khan, A., Khan, J. and 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>.
- Yan, L., Zhou, S. and Feng, L. (2007). Delineation of Site-Specific Management Zones Based on Temporal and Spatial Variability of Soil Electrical Conductivity. *Pedosphere*, 17(2), 156–164.
- Yan, Y., Xu, X., Xin, X., Yang, G., Wang, X., Yan, R. and Chen, B. (2011). Effect of vegetation coverage on aeolian dust accumulation in a semiarid steppe of northern China. *CATENA*, 87(3), 351–356.
- Yari, A., Madramootoo, C.A., Woods, S.A., Adamchuk, V.I. and Huang, H.H. (2017). Assessment of field spatial and temporal variabilities to delineate site-specific management zones for variable-rate irrigation. *Journal of Irrigation and Drainage Engineering*, 143(9), 04017037.
- Zhang, C., Walters, D. and Kovacs, J.M. (2014) Applications of low altitude remote sensing in agriculture upon farmers' requests - a case study in northeastern Ontario, Canada. *PloS One*, e112894. <https://doi: 10.1371/journal.pone.0112894>.

## CAPÍTULO 4

### CLASIFICACIÓN DE ÁRBOLES ENFERMOS EN UNA HUERTA DE NARANJA MEDIANTE APRENDIZAJE AUTOMÁTICO E IMÁGENES DE MUY ALTA RESOLUCIÓN ESPACIAL

Manuscrito en revisión en: *Scientia Agropecuaria*

#### RESUMEN

Este trabajo presenta los resultados de una metodología diseñada para la identificación de árboles de naranja enfermos en una huerta ubicada en el cinturón citrícola de México, particularmente en la región de Rioverde, San Luis Potosí. Para ello, se tomaron imágenes con una cámara multiespectral 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 emplearon 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, clasificación, cítricos, México, vehículo aéreo no tripulado.

## ABSTRACT

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 Potosi. 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, classification, citrus, Mexico, unmanned aerial vehicle.

## 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 han afectado a los árboles de naranja, dos ejemplos destacados son el huanglongbing (HLB) (Berk, 2016) y la tristeza de los cítricos (Hajeri y 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 (Spren *et al.*, 2020), reducir la calidad de la fruta (Bassanezi *et al.*, 2021) 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 y 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 generaron de 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.

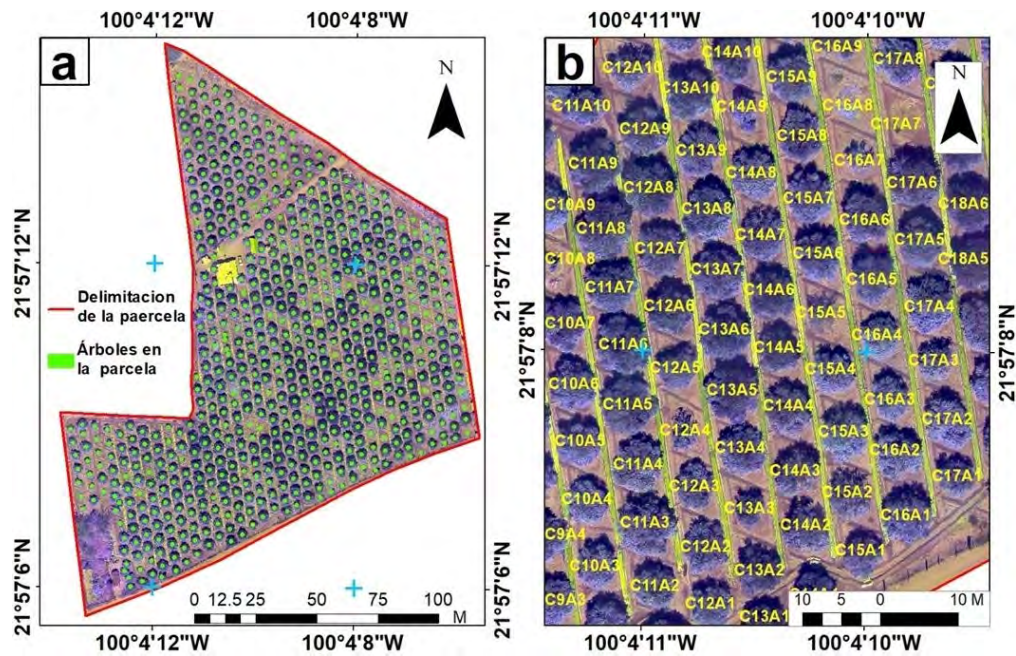
El objetivo de este trabajo fue identificar árboles de naranja enfermos en un huerto ubicado en el Valle de Rioverde, San Luis Potosí, México, utilizando datos de alta resolución espacial recopilados mediante vuelos de vehículos aéreos no tripulados (UAV). Para ello, se evaluó el desempeño de cinco algoritmos de aprendizaje automático los cuales incluyen Random Forest, K-Nearest Neighbor, Spectral Angle Mapper, Support Vector Machine y Maximum Likelihood.

## **MATERIALES Y MÉTODOS**

### **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.

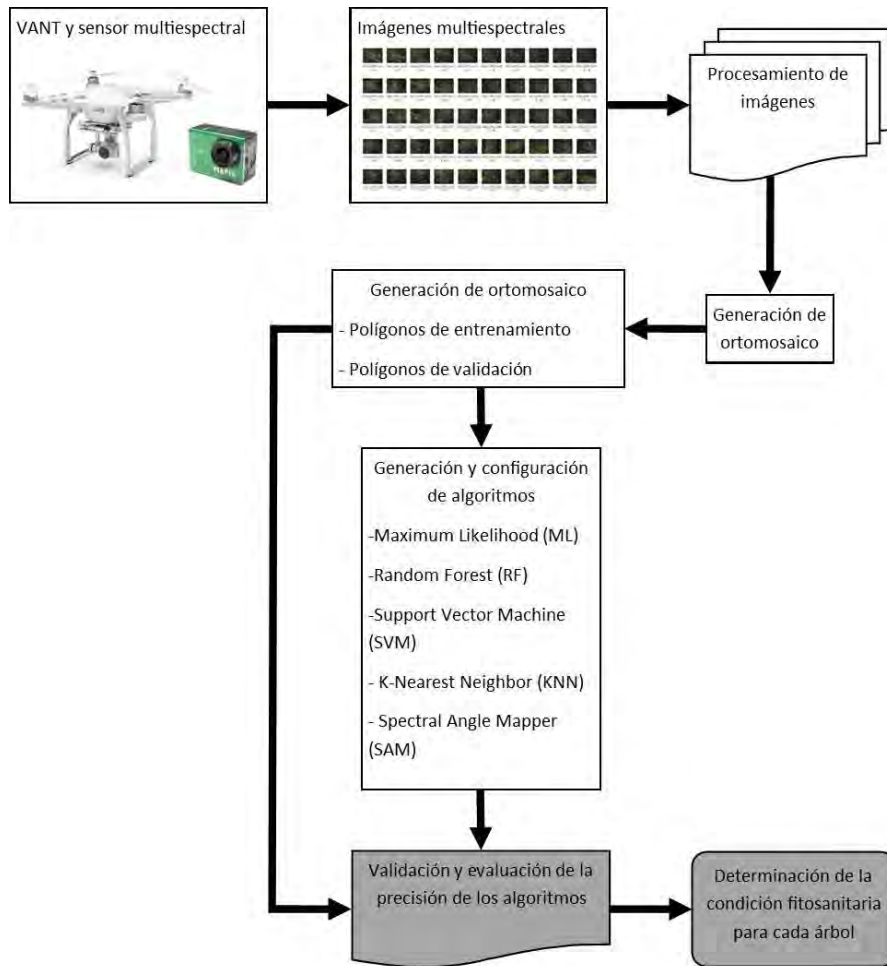
Se realizó un inventario de árboles de la huerta, en el que se registraron 632 árboles colocados en línea de 8 X 8 m (Figura 1a). En este inventario se incluyeron los espacios en donde actualmente no hay árboles debido a que fueron cortados por el productor o se cayeron por enfermedad, ya que esos árboles 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.



**Figura 1.** a) Área de estudio e inventario de árboles. b) Acercamiento para visualizar la clave de identificación de árbol.

### Descripción de la Metodología

Este trabajo se desarrolló en ocho etapas principales (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.



**Figura 2.** Diagrama de flujo de la metodología.

## Algoritmos Empleados

### 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.

### **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. 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), estimación de biomasa de una comunidad vegetal altoandina (Estrada-Zuñiga *et al.*, 2022), la clasificación de tipos de bosques en paisajes en restauración (Scheeres *et al.*, 2023), entre otros.

### **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 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.

### **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 más cercanos en el espacio de características. 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 infectados 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 y Lee, 2021).

### **Spectral Angle Mapper (SAM)**

El algoritmo de Spectral Angle Mapper (SAM) es una técnica utilizada 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 detección y mapeo de árboles infectados con gomosis de cítricos con datos hiperespectrales de UAV (Moriya *et al.*, 2021).

### **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 1.280 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<sup>-1</sup>, 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), realizando el flujo de proceso fotogramétrico para obtener un ortomosaico en formato Geo TIF con una resolución espacial de 5 cm píxel<sup>1</sup> y se le aplicó una calibración de reflectancia, fue georreferenciado con 8 puntos de control terrestre obtenido 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.

### Generación de Modelos

Mediante recorridos en la huerta en compañía del productor, se realizó un análisis visual sobre cada árbol para estimar el daño de afectación 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.



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

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 a los recorridos realizados en campo. 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 bien 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% se utilizaron para validar los resultados (Barman y 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 Geoprociamiento 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.

### **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 y Huayna (2022), utilizaron índices espectrales como el NDVI, para determinar el grado de afectación por ataque de plagas en árboles frutales. De acuerdo a



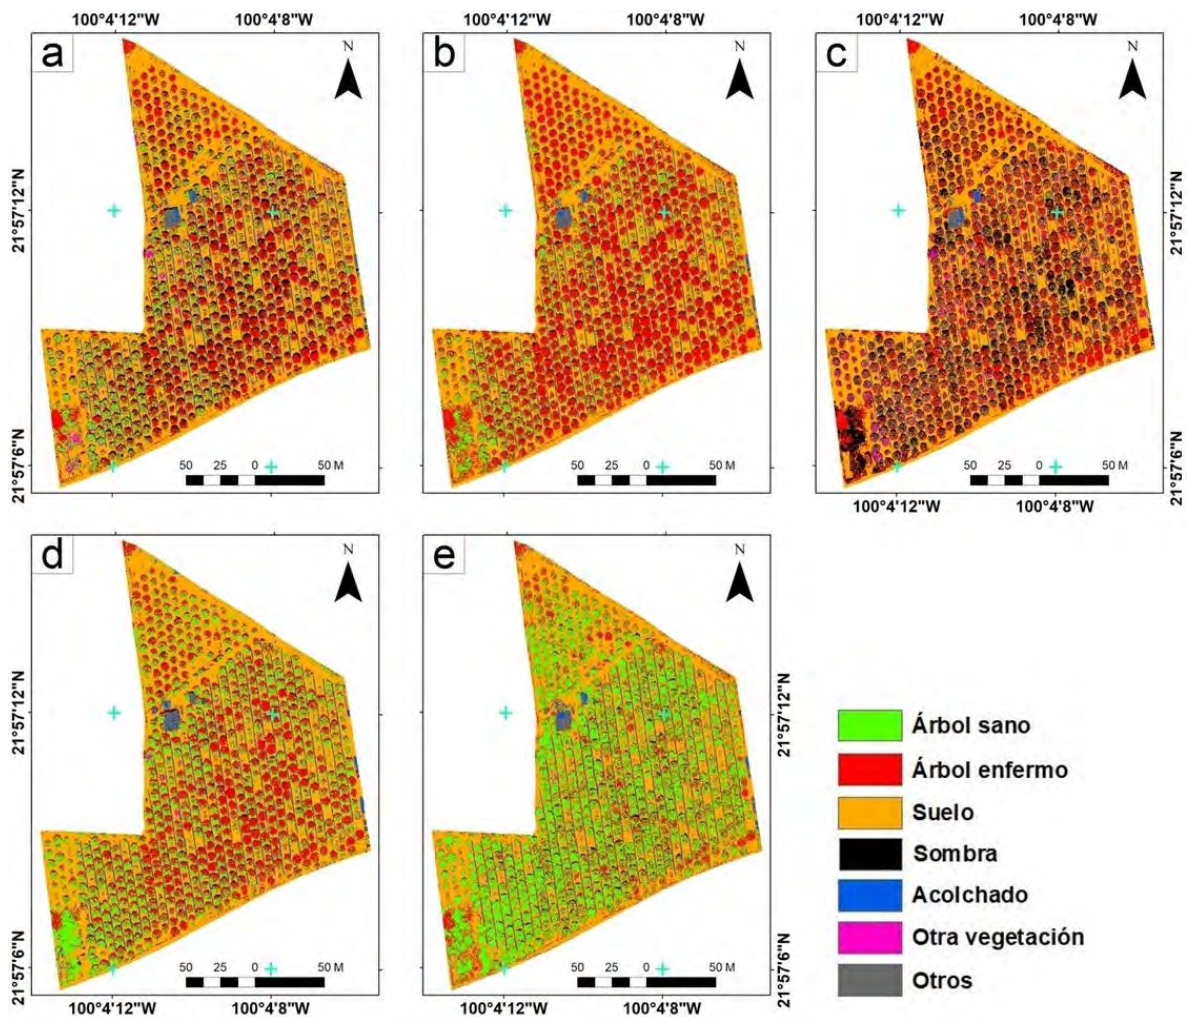
la experiencia del productor, un árbol de naranja se puede considerar sano cuando tres cuartas partes de la copa se encuentra en esta condición (75%), un árbol en estrés, cuando la copa sana se encuentra entre el 60 y 75% y un árbol enfermo cuando la copa sana es menor al 60%. De manera común, todos 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.

## RESULTADOS

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 citada indica que este algoritmo obtiene buenos resultados cuando se usa con imágenes donde no se perciben los objetos con mucho detalle, 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.



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

### 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 el Cuadro 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.

**Cuadro 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	
2		Sombra	0.06	
2		Suelo	0.03	
2		Árbol enfermo	5.29	Sí
2		Árbol sano	1.41	
5	Árbol enfermo	Sombra	0.11	
5		Árbol enfermo	7.23	Sí
5		Árbol sano	1.72	
7	Árbol enfermo	Otra vegetación	0.04	
7		Árbol enfermo	3.1	
7		Árbol sano	3.38	No
12	Árbol enfermo	Árbol enfermo	6.35	Sí
12		Árbol sano	0.52	
14	Árbol enfermo	Sombra	0.21	
14		Árbol enfermo	3.02	Sí
14		Árbol sano	1.72	
19	Árbol enfermo	Árbol enfermo	7.74	Sí
19		Árbol sano	0.51	
21		Árbol enfermo	5.57	Sí

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 al área que abarca en cada polígono de validación al superponerse en los modelos generados de los cinco algoritmos. Se obtuvo el porcentaje de efectividad de acierto por cada clase para cada algoritmo (Cuadro 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%, incluido la case “otros” con un 0% de efectividad, es importante recalcar que fue el único algoritmo que predijo al 100% la clase árbol sano.

**Cuadro 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.

### **Determinación la Condición Fitosanitaria de Cada Árbol**

El inventario realizado en la huerta arrojó un total de 677 puntos. 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 el Cuadro 3 se muestran los resultados de la condición fitosanitaria de cada árbol obtenidos por cada modelo.

**Cuadro 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 el Cuadro 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 a las observaciones que se realizaron en los recorridos de la huerta existen 427 árboles enfermos y 174 árboles sanos.

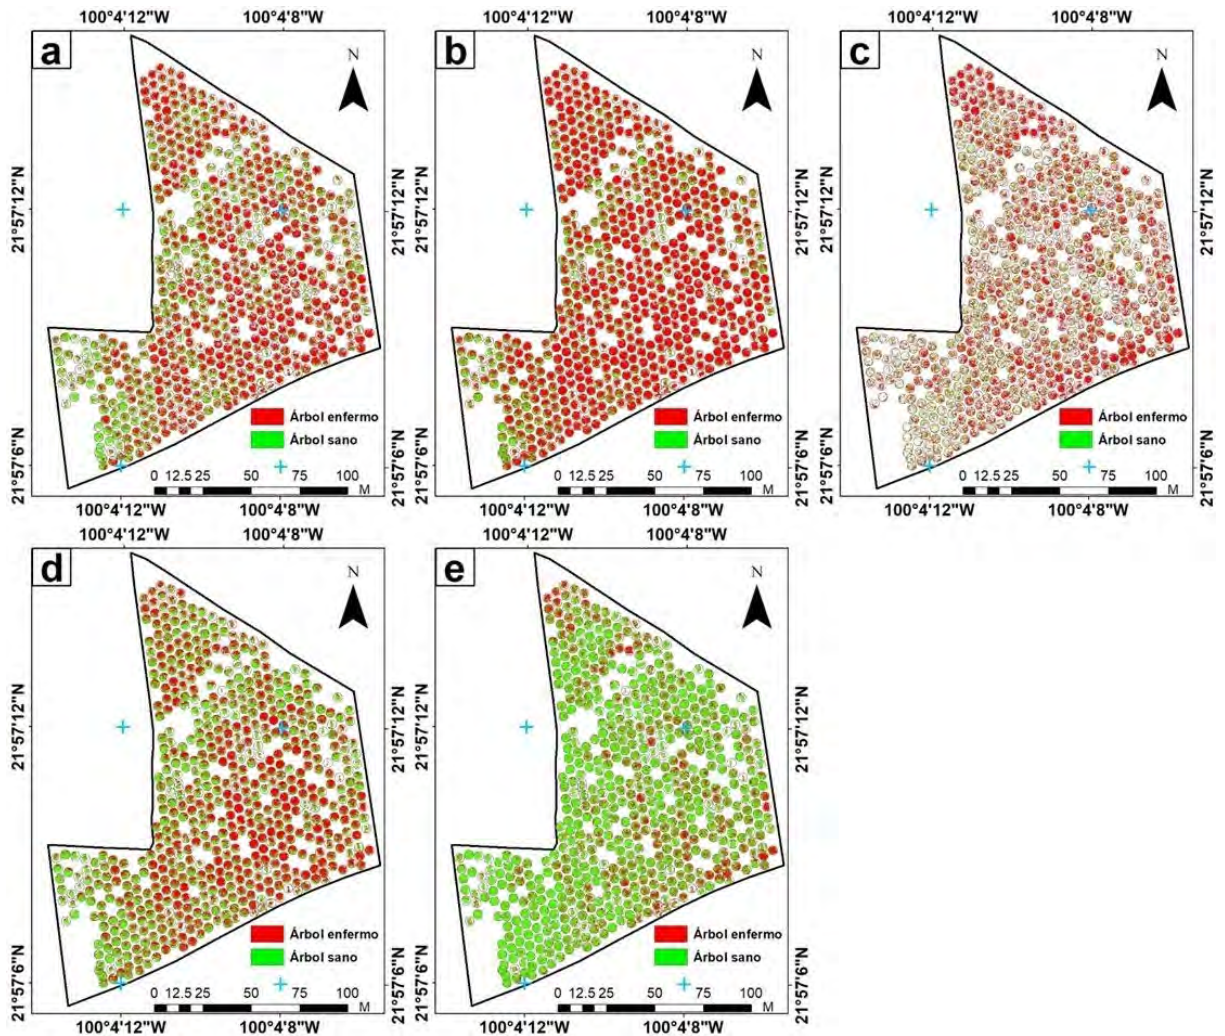
**Cuadro 4.** Fragmento de la evaluación de la condición fitosanitaria para cada árbol.

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

De acuerdo a 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 contra parte 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 cuales 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 tendencia a clasificar arboles enfermos y sanos respectivamente.



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

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.

## DISCUSIÓN

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 a los resultados, las sombras generadas por los árboles provocan conflicto en los algoritmos confundiéndolos 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 genera algunos errores de clasificación, 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%.

Aunque kNN y RF obtuvieron rendimientos bajos, fueron capaces de predecir al 100% árboles enfermos (kNN) y árboles sanos (RF). 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 contra parte de árboles sanos y enfermos. Su bajo rendimiento se observó al revisar que las clasificaciones predecían de manera marginal, las demás clases temáticas. 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%.

En general la precisión de la clasificación para los diferentes métodos puede variar de acuerdo al 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 y 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 sólidos 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.

Las técnicas de validación ayudan notablemente para mejorar 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) utilizó pruebas de reacción en cadena de la polimerasa (PCR) para detectar árboles infectados con HLB lo cual mejoró notablemente la precisión de sus resultados. Los 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 es la clase más uniforme en cuanto a la reflectancia de sus píxeles. En lo que respecta a la clasificación de árboles sanos y enfermos, algunas investigaciones mencionan que los algoritmos tienden a tener preferencias de clasificación tanto para árboles sanos o árboles enfermos. En las investigaciones de Lan *et al.* 2020 y Barman y Choudhury 2022 los algoritmos tendieron a clasificar 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.

Los datos del Servicio de Información Agroalimentaria y Pesquera (SIACON, 2021), muestran que, para 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 Ton) 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 el rendimiento.

## **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 citrícola 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 orto-

mosaico 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.

## LITERATURA CITADA

- Abdulridha, J., Batuman, O. and 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. and 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. and 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. and 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. and 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. and 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. y Gómez-Cadenas, A. (2021). El futuro de los cítricos: Impacto del cambio climático en la citricultura. *Mètode Science Studies Journal*, 110, 61–67. <https://doi.org/10.7203/metode.12.20319>.

- Barman, U. and 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.gltip.2021.10.004>.
- Bassanezi, R. B., Primiano, I. V. and 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. and 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. and 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. and 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. and 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. and 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. and 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., Mokrini, F., Özer, G., Lazraq, A., Belabess, Z., Amiri, S. and Lahlali, R. (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.pmpp.2021.101753>.

Freitas, T.A., Proença, C.A., Baldo, T.A., Materón, E.M., Wong, A., Magnani, R.F. and 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>.

Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J. and 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 erytreae*, vector of citrus greening disease. *Crop Protection*, 168, 106228. <https://doi.org/10.1016/j.cropro.2023.106228>.

Hajeri, S. and 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. and 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:10.1080/01431160110040323>.

Kruse, F. A., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J. and 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. and Mangan, R. L. (2012). Citrus greening disease detection using aerial hyperspectral and multispectral imaging techniques. *Journal of Applied Remote Sensing*, 6, 063542. <https://doi:10.1117/1.JRS.6.063542>.

Lan, Y., Huang, Z., Deng, X., Zhu, Z., Huang, H., Zheng, Z., Lian, B., Zeng, G. and Tong, Z. (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. and Yang, C. (2013). Extended spectral angle mapping (ESAM) for citrus greening disease detection using airborne hyperspectral imaging. *Precision Agriculture*, 15(2). <https://doi: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. and 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., and Zennayi, 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., and 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. and 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., Zambrano, A. M. A., Gorgens, E. B., Silva, C. A., Valbuena, R., Molin, P., Stark, S., Rodrigues, R. R., Santoro, G. B., Resende, A. F., De Almeida, C. T. and De Almeida, D. R. A. (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. and 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. and 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. and 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>.
- Xie, C., and 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., and 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., and 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, I., Amin, Z. M., and 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>.



## CAPÍTULO 5

### IMPACTO DE LA PRECIPITACIÓN SOBRE LA APTITUD DEL SUELO PARA EL CULTIVO DE NARANJA EN UNA REGIÓN SEMIÁRIDA DE MÉXICO SOME GEOSPATIAL INSIGHTS ON ORANGE GROVE SITE SELECTION IN A PORTION OF THE NORTHERN CITRUS BELT OF MEXICO

Manuscrito publicado en: AgriEngineering

#### RESUMEN

Este estudio tuvo como objetivo delinear las áreas más adecuadas para la producción sostenible de cítricos mediante la integración de análisis de decisión multicriterio, teledetección de series de tiempo y análisis de componentes principales en una porción del cinturón cítrico del norte de México, particularmente en el Valle de Rioverde. Se agruparon catorce factores específicos en cuatro factores principales, es decir, topografía, suelo, clima y proximidad a fuentes de agua, para llevar a cabo un análisis de decisión multicriterio para clasificar las áreas de producción según niveles de aptitud. Para explorar el efecto de la precipitación sobre la aptitud del suelo para la producción de cítricos, analizamos el registro histórico de precipitación anual estimado mediante el procesamiento de datos diarios del NDVI de 20 años. El modelo multicriterio se ejecutó para cada año de precipitación. El mapa final de aptitud del suelo se obtuvo utilizando el primer componente después del análisis de componentes principales en mapas anuales de aptitud del suelo. Los resultados muestran que casi el 30% del área de estudio se encuentra dentro de una aptitud moderada y alta para el cultivo de naranjos. El estudio destacó la importancia de las precipitaciones en series temporales basadas en datos de sensores remotos para predecir la aptitud potencial del suelo para el cultivo de naranjos en tierras semiáridas. Nuestros resultados pueden apoyar los procesos de toma de decisiones para el manejo efectivo del suelo de las huertas de naranja en la región de Rioverde en México.

**Palabras clave:** MCD43A4, análisis multicriterio, análisis de componentes principales, series de tiempo, México

## **ABSTRACT**

This study aimed to delineate the most suitable areas for sustainable citrus production by integrating multicriteria decision analysis, time-series remote sensing, and principal component analysis in a portion of the northern citrus belt of Mexico, particularly in the Rioverde Valley. Fourteen specific factors were grouped into four main factors, i.e., topography, soil, climate, and proximity to water sources, to carry out a multicriteria decision analysis for classifying production areas according to suitability levels. To explore the effect of precipitation on land suitability for citrus production, we analyzed the historical record of annual precipitation estimated by processing 20-year NDVI daily data. The multicriteria model was run for every precipitation year. The final map of land suitability was obtained by using the first component after principal component analysis on annual land suitability maps. The results show that nearly 30% of the study area is within moderate and high land suitability for growing orange groves. The study highlighted the importance of remotely sensed data-based time-series precipitation in predicting potential land suitability for growing orange groves in semiarid lands. Our results may support decision-making processes for the effective land management of orange groves in the Mexico's Rioverde region.

**Keywords:** MCD43A4, multicriteria decision analysis, principal component analysis, time-series, Mexico

## **INTRODUCCIÓN**

México es el quinto país productor de naranjas más importante del mundo, después de Brasil, Estados Unidos, China e India. La producción de naranja mexicana se distribuye principalmente en cuatro estados, entre ellos Veracruz, Tamaulipas, San Luis Potosí y Nuevo León. Particularmente en el estado de San Luis Potosí, la región de Rioverde produce naranjas de calidad, lo que le otorga un alto valor en el mercado (USDA 2021).

Durante 2019 y 2020, San Luis Potosí exhibió una producción aproximada de 190.000 t de naranja (*Citrus sinensis*) y en particular, la región Rioverde produjo 120,000 t en un área sembrada de 5,650 ha, es decir, aproximadamente el 60% de la producción de naranjas de todo el estado, posicionando a la región Rioverde como la mayor productora de cítricos del estado de San Luis Potosí (SAGARPA, 2021).

La producción de naranjas en México ha enfrentado varias limitaciones durante la última década, incluida la escasez de agua, enfermedades y cambios en el uso del suelo. La producción de naranjas depende en gran medida del agua subterránea de los pozos, que se recargan con las precipitaciones anuales. Sin embargo, una sequía reciente, que resultó en una disminución de las precipitaciones, ha planteado una amenaza a la producción de naranjas en el área de estudio (Dalin *et al.*, 2017; Campos-Aranda, 2018). Por lo tanto, la escasez de agua, debido principalmente a anomalías en las precipitaciones (Chávez, 2021; Dobler-Morales y Bocco, 2021; USDA 2023), ha generado problemas de plagas y enfermedades (Hernández-Morales *et al.*, 2021). Además, existen otras causas para la disminución del área de naranjos, incluido el cambio de uso del suelo impulsado principalmente por el crecimiento urbano. El crecimiento urbano afecta a las huertas de naranja por varias razones: 1) falta de rentabilidad en la producción de naranjas causada por enfermedades de los cultivos, lo que lleva a decisiones de vender sus tierras a desarrolladores urbanos, 2) las huertas de naranja son heredadas por herederos, pero no quieren ser agricultores, por lo tanto, ellos mismos deciden vender sus terrenos a promotores urbanos y 3) la misma familia decide construir dentro de la arboleda (van Vliet *et al.*, 2017).

Los sistemas de información geográfica se han utilizado para evaluar la aptitud de del suelo para la producción de cultivos. Seleccionar ubicaciones potenciales para establecer nuevos huertos frutales es una cuestión importante para planificar el uso futuro del suelo hacia la agricultura sostenible (Shaloo *et al.*, 2022). Un método ampliamente utilizado para mapear la aptitud del suelo es el llamado análisis multicriterio (MCDA). Este método se ha utilizado para resolver problemas complejos combinando numerosas variables en diferentes niveles de interacción (Malczewski, 2004; Cicciù *et al.*, 2022). Algunas aplicaciones agrícolas del MCDA en la agricultura se pueden encontrar en la literatura

reciente, por ejemplo, la aptitud del suelo para cultivos de té (Li *et al.*, 2012), *Eragrostis tef* para la producción de harina en la fabricación de pan (Flynn, 2019), la aptitud del suelo para el trigo (Dedeoğlu y Dengiz, 2019), aptitud del suelo para la producción de cebada (Seyedmohammadi *et al.*, 2019), producción de arroz (Amini *et al.*, 2020), aptitud del suelo para trigo y maíz (Pilevar *et al.*, 2020), aptitud del suelo para maíz (Tashayo *et al.*, 2020) y la aptitud del suelo para *Moringa oleifera* (Tshabalala *et al.*, 2020).

En particular, para cultivos de cítricos, Elsheikh *et al.*, (2013) desarrollaron una herramienta para evaluar la aptitud de los suelos agrícolas para la planificación de cultivos tropicales y subtropicales, incluidos los cítricos en Malasia. Zabihi *et al.*, (2015) mapearon la aptitud del suelo para la planificación sostenible de cítricos en una región del norte de Irán utilizando el proceso de red analítica (ANP) dentro de un entorno SIG. Mokarram y Mirsoleimani (2018) mapearon la aptitud del suelo para cultivos de cítricos en la provincia de Fars, Irán, utilizando un análisis de decisiones multicriterio. Tercan y Dereli (2020) desarrollaron un modelo de aptitud del suelo para el cultivo de cítricos en la región mediterránea de Turquía. Orhan (2021) determinó la aptitud del suelo para el cultivo de cítricos utilizando MCDA en Mersin, Turquía. Aunque los estudios mencionados anteriormente han hecho contribuciones significativas al uso de MCDA en el contexto de los cultivos de cítricos, nuestra motivación fue evaluar factores biofísicos, por ejemplo, la precipitación interanual estimada mediante datos de sensores remotos, posiblemente relacionados con la aptitud del suelo para el cultivo de cítricos.

El análisis de componentes principales (PCA, por sus siglas en inglés) es una técnica multivariada para la reducción de la dimensión de los datos utilizada en múltiples campos de estudio (Jolliffe, 2002). En el contexto de la ciencia espacial, el PCA se puede utilizar espacial y temporalmente. Cuando se usa espacialmente, esta técnica se puede aplicar para resaltar características espectrales en datos de sensores remotos, por ejemplo, en una escena satelital de fecha única, PCA puede fusionar bandas espectrales en nuevos componentes principales que capturan características biofísicas como la clorofila (verdor) y la humedad ambiental (Millward *et al.*, 2006). Los investigadores han creado imágenes compuestas RGB con los tres primeros componentes principales para enfatizar las características espectrales de la cobertura natural (Aguirre-Salado *et al.*, 2012), otros han

utilizado PCA como técnica de detección de ruido (Corner *et al.*, 2000) y, además, otros lo han utilizado como técnica de eliminación de ruido (Mohan-Babu *et al.*, 2012). Cuando se usa temporalmente, esta técnica se puede emplear en datos de series de tiempo para analizar patrones temporales de una sola variable, por ejemplo, NDVI. En este caso, el primer componente principal asimila todo el comportamiento radiométrico común a toda la serie temporal. El segundo componente principal incorpora características no incluidas en el primer componente principal y se interpreta como un componente para el análisis de cambio (Lasaponara, 2006; Miranda-Aragón *et al.*, 2012).

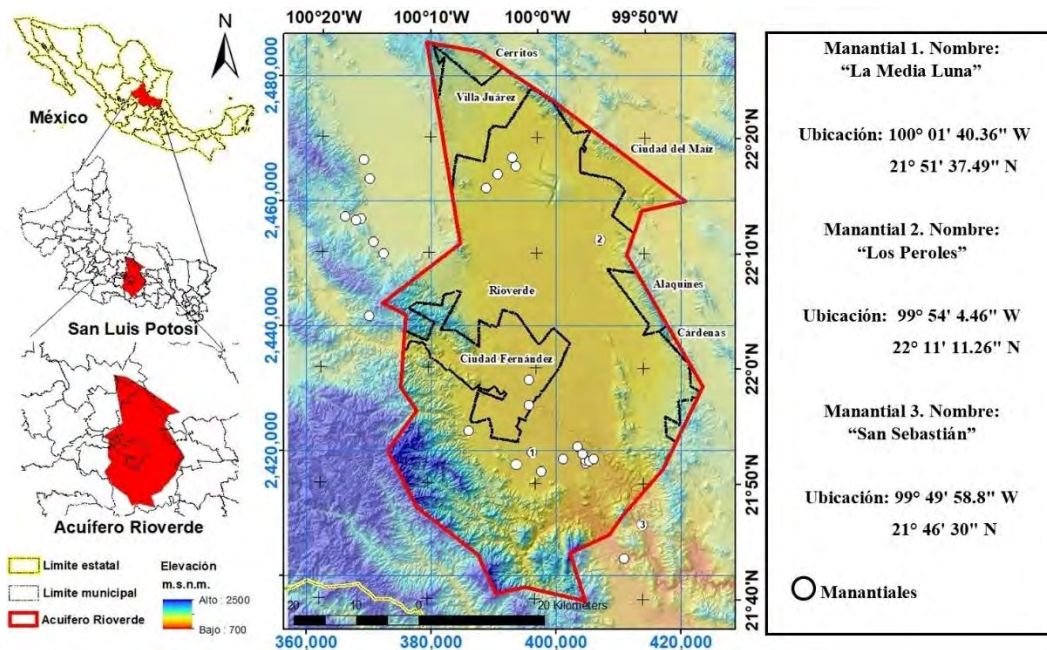
La agricultura de precisión en suelos semiáridos es un desafío (Rosegrant *et al.*, 2009). Los agricultores deben abordar la escasez de agua cuando producen cultivos especiales para satisfacer la demanda local y externa de productos alimenticios (Majsztrik *et al.*, 2019). La teledetección desempeña un papel clave en el seguimiento de las variables ambientales, por ejemplo, las precipitaciones, para la producción agrícola en tierras semiáridas (Jurišić *et al.*, 2021). En particular, los índices espectrales construidos utilizando datos de series temporales de sensores remotos pueden usarse como sustitutos para el monitoreo de las precipitaciones (Svoboda y Fuchs, 2016). Como una auténtica preocupación sobre la continuidad del cultivo de naranjos en la región de Rioverde, esta investigación fue diseñada para investigar el estado de aptitud del suelo para el cultivo de naranjos bajo una perspectiva espaciotemporal utilizando datos de series temporales de 20 años de sensores remotos como indicador de la precipitación en el contexto del enfoque MCDA mediante la combinación de diferentes criterios, incluidos la topografía, el suelo, clima y factores de proximidad, en la región de Rioverde en México.

## **MATERIALES Y MÉTODOS**

### **Área de Estudio**

Este estudio se realizó en una porción del cinturón citrícola de México, particularmente en la región de Rioverde en la zona media del estado de San Luis Potosí. El área de estudio se ubica dentro de los límites político-administrativos del acuífero Rioverde, el cual está

delimitado entre los meridianos 100° 15' 36.19" y 99° 44' 52" W y los paralelos 22° 29' 35" y 21° 38' 12" N (**Figura 1**), con una superficie de 2,782.66 km<sup>2</sup> (DOF, 2014).



**Figura 1.** Localización del área de estudio.

Este acuífero es granular y su dinámica depende en gran medida de la abundancia de precipitaciones anuales. Más del 80% de la producción de naranja en la región de Rioverde depende del agua subterránea obtenida de pozos. En 2015 y 2020, el acuífero Rioverde exhibió una disponibilidad anual de agua de 78,842,614 m<sup>3</sup> y 29,582,580 m<sup>3</sup>, respectivamente (CONAGUA 2015, 2020), como evidencia del agotamiento del agua subterránea.

El área de estudio es mayoritariamente plana con elevaciones promedio de aproximadamente 1.000 m.s.n.m. en dirección suroeste, sin embargo, emergen algunas montañas con elevaciones que van desde los 900 a los 2170 m.s.n.m. (INEGI, 2012). El clima es de estepa seca en las tierras bajas del norte, hacia el suroeste la humedad ambiental aumenta paulatinamente, volviéndose templado lluvioso. La temperatura media anual es de 21.5°C. Las precipitaciones se producen normalmente en verano, con una precipitación media anual de 484 mm. La temperatura puede alcanzar hasta 40°C en primavera y verano, y el invierno suele ser fresco (Yáñez-Rodríguez, 2019).

El valle de Rioverde está cubierto por aproximadamente 18 manantiales (Díaz-Rivera, 2018), que abastecen de agua para las actividades humanas, incluida la agricultura y el consumo urbano. Algunos de ellos son origen de pequeños cuerpos de agua que son visitados por turistas, ej., el manantial conocido como “La Media Luna” ubicado a  $100^{\circ} 01' 40.36''$  W,  $21^{\circ} 51' 37.49''$  N, el manantial conocido como “ Los Peroles” ubicado a  $99^{\circ} 54' 3.6''$  W,  $22^{\circ} 11' 13.2''$  N, y el manantial conocido como “San Sebastián” ubicado a  $99^{\circ} 49' 58.8''$  W,  $21^{\circ} 46' 30''$  N, entre otros . El agua subterránea en la parte norte del acuífero Rioverde generalmente se caracteriza por altos niveles de sulfato de calcio y bicarbonato de calcio, lo que puede resultar en agua de menor calidad que puede no ser apta para beber u otros fines. Sin embargo, en la región sur del acuífero, la calidad del agua es generalmente mayor y el agua subterránea a menudo se considera potable o segura para el consumo humano (Charcas-Salazar *et al.*, 2002).

### **Datos Utilizados**

Los conjuntos de datos espaciales utilizados para llevar a cabo el análisis de aptitud del suelo para el cultivo de naranjos en la región de Rioverde se presentan en la Figura 2, construimos cuatro criterios principales utilizando 14 subcriterios. Los principales criterios fueron los siguientes: topografía, suelo, disponibilidad de agua y clima. El criterio de topografía estaba compuesto por tres subcriterios, incluyendo elevación, pendiente y orientación. El criterio del suelo estuvo compuesto por los subcriterios pH, profundidad del suelo, conductividad eléctrica y textura del suelo. Los criterios climáticos se construyeron con humedad relativa, precipitación, temperatura media mínima y temperatura media máxima. El criterio de proximidad a los recursos hídricos recogió la variabilidad espacial de la distancia a ríos y arroyos, distancia a manantiales y distancia a pozos.

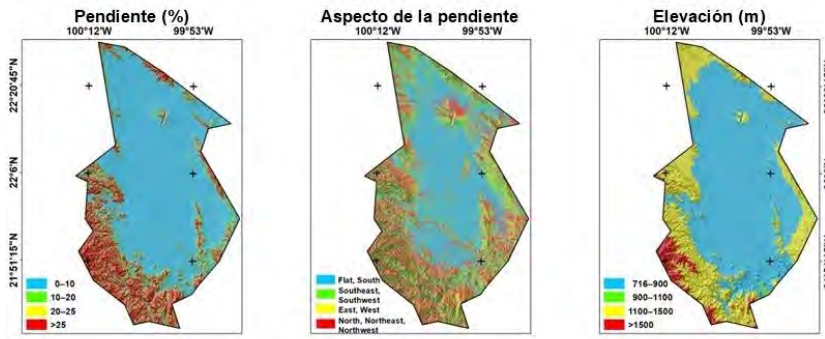
El criterio topográfico se consideró utilizando un modelo digital de elevaciones con una resolución espacial de 15 m obtenido del Instituto Nacional de Estadística y Geografía (INEGI, 2012). La pendiente y la orientación se obtuvieron procesando el modelo digital de elevaciones utilizando un sistema de información geográfica.

El criterio de suelo se construyó utilizando el mapa nacional de suelos para extraer clases temáticas de textura del suelo. Los mapas de suelos utilizados fueron San Luis Potosí (F14-4), Ciudad Mante (F14-5), Guanajuato (F14-7) y Ciudad Valles (F14-8) (INEGI 2007a, 2007b, 2007c, 2007d), y para variables cuantitativas del suelo, se utilizó la base de datos nacional de perfiles de suelo, que incluye casi 4,418 datos puntuales sobre las características del suelo (INEGI, 2013). Extrajimos datos de 42 puntos para construir conjuntos de datos espaciales de profundidad del suelo, pH y conductividad eléctrica utilizando el algoritmo de ponderación de distancia inversa tomando 12 vecinos más cercanos y un tamaño de píxel de 15 m de resolución espacial como el modelo digital de elevaciones (Sannidi *et al.*, 2022).

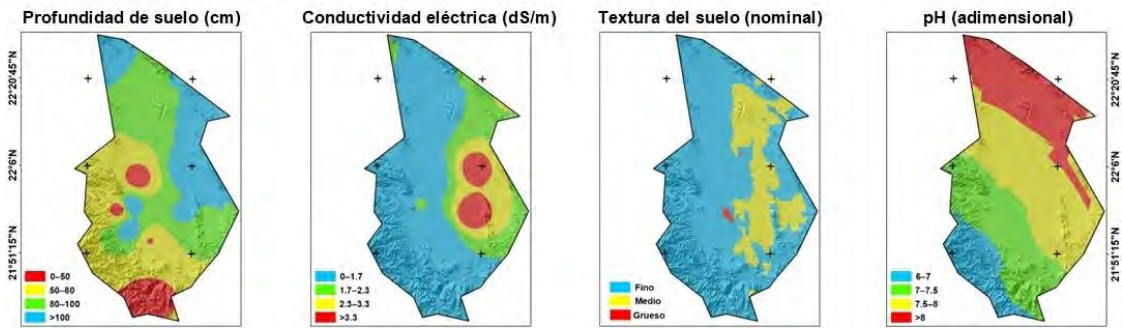
Respecto al criterio climático, la humedad relativa se construyó con datos recopilados en un periodo de 1961 a 1990 por la Unidad de Investigación Climática de la Universidad de East Anglia (New *et al.*, 2002; CRU, 2015), y las temperaturas medias mínimas y máximas se obtuvieron de 33 estaciones meteorológicas operadas por el Servicio Meteorológico Nacional (CONAGUA, 2010). Estas estaciones climáticas incluyen datos recopilados durante un período superior a 50 años. Los datos puntuales de humedad relativa, temperatura media mínima y máxima, se interpolaron utilizando el algoritmo de ponderación de distancia inversa que utilizó 12 vecinos más cercanos y una resolución espacial de 15 m (Boz *et al.*, 2020). La precipitación se obtuvo utilizando



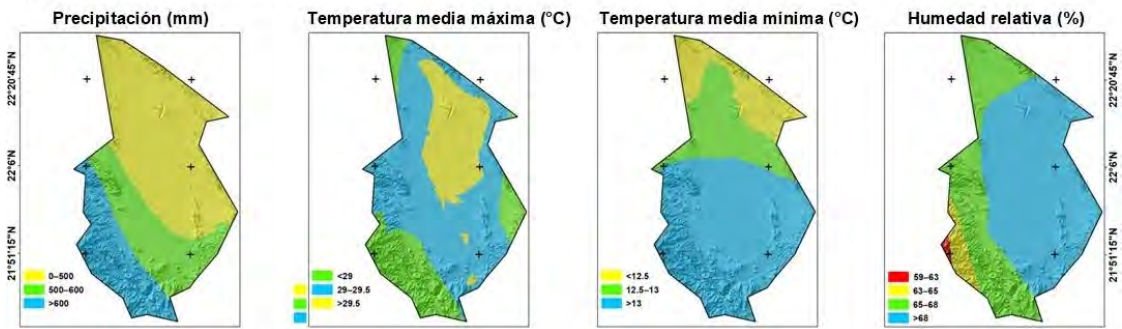
a) Criterios topográficos



b) Criterios de suelo



c) Criterios climáticos



d) Criterios de proximidad a fuentes de agua

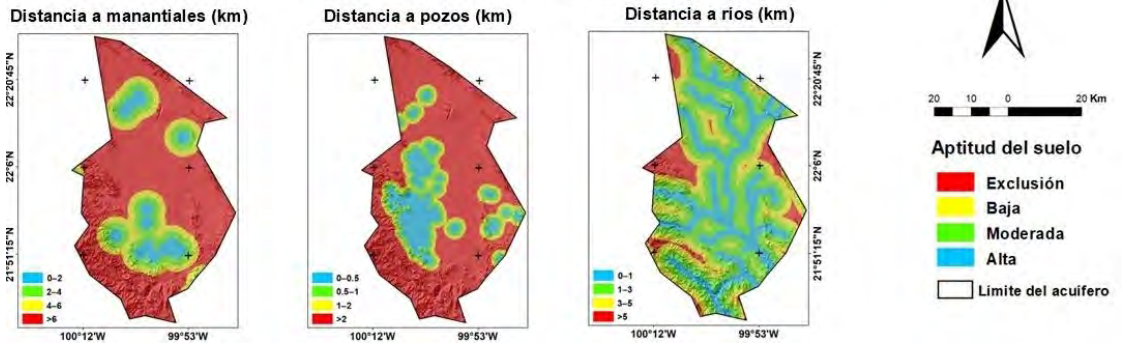


Figura 2. Variables utilizadas en el análisis.

datos de series temporales captados remotamente. Para ello, se descargaron datos diarios del producto MODIS MCD43A4 de la plataforma Earth Data Search (<https://search.earthdata.nasa.gov/>) para el período del 24 de febrero del 2000 al 31 de diciembre de 2019, con un total de 20 años de observaciones diarias por teledetección. Estos datos se descargaron en una proyección cartográfica sinusoidal y fueron re proyectados primero en Platé-Carrée y luego en Universal Transverse Mercator (UTM). Se utilizaron bandas rojas e infrarrojas para calcular el Índice de Vegetación de Diferencia Normalizada (NDVI) diariamente (Rouse *et al.*, 1974; Xu *et al.*, 2022). El NDVI máximo anual se calculó utilizando el algoritmo compuesto de valor máximo (Holben, 1986; Cheng *et al.*, 2022). Luego de obtener el NDVI máximo para cada año, utilizamos la ecuación propuesta por Miranda-Aragón *et al.* (2012) para estimar la precipitación anual.

El criterio de disponibilidad de agua trazado por la distancia a los ríos se creó utilizando datos vectoriales de mapas topográficos a escala 50,000 (INEGI, 2018). Los mapas utilizados fueron Cerritos (F14A76), Peotillos (F14A75), La Angostura (F14A86), San Francisco (F14A87), Rio Verde (F14C17), La Libertad (F14A77), Tierra Nueva (F14C25), San Ciro (F14C27), Mineral El Realito (F14C26), Santa Catarina (F14A85), El Refugio (F14C16) y La Salitrera (F14C15). La distancia a los manantiales se creó utilizando datos de 18 puntos georreferenciados recopilados por los autores en campañas de campo durante junio de 2017. La distancia a los pozos se creó utilizando datos de 520 puntos de una base de datos recopilada por la Comisión Nacional del Agua (CONAGUA, 2020). Una vez que se prepararon los datos vectoriales, se ejecutó el algoritmo de distancia euclidiana para obtener conjuntos de datos ráster de distancia a ríos y arroyos, distancia a manantiales y distancia a pozos.

### **Criterios de Estandarización**

Los criterios involucrados en la determinación de la aptitud del suelo para el cultivo de naranjos interactúan de diferentes maneras. Para hacerlos más apropiados para contabilizar la aptitud del suelo para los huertos de naranjos, los criterios se estandarizaron utilizando una escala del 1 al 4, dando una puntuación mayor a los valores más altos de aptitud del suelo para naranjos y viceversa, y utilizando literatura técnica sobre los límites

biológicos de crecimiento de naranja (Ruiz-Corral *et al.*, 2013). Los criterios involucrados en la determinación de la aptitud del suelo para el cultivo de naranjos se describen cuantitativamente en el Cuadro 1.

La topografía influye en la productividad de los naranjos. La elevación recomendada para el cultivo de naranja es entre 500 a 1800 m.s.n.m. en los trópicos (Doorembos y Kassam, 1979). La elevación oscila entre los 700 y los 2170 m.s.n.m. en el área de estudio. Se clasificó en cuatro clases de aptitud del suelo basándose en el razonamiento de que una elevación más baja fomenta una mayor productividad en el área de estudio. Las tierras bajas del área de estudio están reservadas para el valle y se espera que sean más adecuadas para el cultivo de naranjas. Elevaciones superiores a los 1500 m.s.n.m. fueron excluidas del análisis debido al alto riesgo de heladas. Por lo general, no se recomienda la pendiente como factor limitante para el crecimiento de las naranjas. Sin embargo, las pendientes suaves favorecen la cosecha. El límite superior de pendiente se estableció en 25% siguiendo las recomendaciones de Zabihi *et al.* (2015), otorgando una mayor puntuación de aptitud a los lugares llanos.

El aspecto de la pendiente está directamente relacionado con la radiación solar y luego con la actividad fotosintética. Aunque el cultivo de naranja es una planta de día neutro, se espera un mejor rendimiento de naranja en lugares con mayor radiación solar. Dado que se supone que los campos de cultivo orientados al sur tienen una mayor radiación solar, se estableció una puntuación de aptitud del suelo basada en el aspecto de la pendiente asignando valores mayores a las orientaciones planas y al sur (Tercan y Dereli, 2020). A las orientaciones restantes se les asignaron simétricamente puntuaciones de aptitud más bajas.

Las características del suelo son esenciales para cultivos de calidad. Los cultivos de naranja crecen aceptablemente en suelos con valores de pH que oscilan entre 4 y 9, con un óptimo entre 5.5 y 6.8. El pH se distribuye de sureste a noroeste en el área de estudio, exhibiendo valores que van desde 6 hasta más de 8. A las ubicaciones con un pH débilmente ácido y neutro (6 y 7) se les asignó una aptitud alta de suelo, mientras que los niveles de aptitud más bajos fueron asignados a las zonas de un pH con valores más altos. Un  $\text{pH} > 8$  se consideró inadecuado para el crecimiento de los naranjos (Molina, 2000).

La profundidad del suelo está extremadamente ligada a la forma del relieve y a los procesos de erosión, por lo tanto, un valle es una zona de captación de suelo. En el área de estudio, la profundidad del suelo se distribuye inversamente en un gradiente de noreste a suroeste. La profundidad efectiva del suelo representa la profundidad máxima a la que las raíces de las plantas penetran sin encontrar obstáculos y luego alcanzan un crecimiento normal. Las raíces del naranjo crecen en el primer metro de profundidad, el 70% del sistema radicular en los primeros 50 cm y el 30% restante en los segundos 50 cm (Ruiz-Corral *et al.*, 2013).

Para el cultivo de naranjas, se prefieren suelos más profundos, por lo tanto, la mayor aptitud del suelo basada en la profundidad del suelo está reservada para suelos profundos. La conductividad eléctrica está relacionada con el contenido de sal en el suelo. Los cultivos de naranja toleran bajos niveles de salinidad en el suelo. Cuando la conductividad eléctrica es inferior a 1,7 dS/m no se observan pérdidas de rendimiento en la producción de naranja. Sin embargo, cuando la conductividad eléctrica está entre 1,7 y 2,3 dS/m, se esperan pérdidas del 10%, entre 2,3 y 3,3 dS/m se esperan pérdidas del 25% y entre 3,3 y 4,8 dS/m, se esperan pérdidas del 50% (Doorembos y Kassam, 1979). Por lo tanto, es preferible una conductividad eléctrica más baja para el cultivo de naranjos. La textura del suelo está fuertemente relacionada con la capacidad de agua disponible en el suelo. Sin embargo, cuando existe un drenaje deficiente, los cultivos de naranja son susceptibles a enfermedades fúngicas (Molina, 2000). Se asignó alta y baja aptitud del suelo a suelos limosos y arcillosos, respectivamente.

El clima influye fuertemente en el crecimiento de la naranja a través de la temperatura y las precipitaciones. Las condiciones de producción más favorables se dan en regiones con climas tropicales y subtropicales entre las latitudes 23.5 y 40° norte y sur. Una mayor tasa de humedad relativa ( $HR > 50\%$ ) influye en el crecimiento de la naranja porque fomenta cáscaras más delgadas en la fruta y mejora la producción de jugo en calidad y cantidad (Anderson, 1996). El área de estudio exhibe una humedad relativa entre 59 y 70%, con un patrón creciente de oeste a este. Este subcriterio se dividió en cuatro clases simétricas siguiendo el trabajo de Tercan y Dereli (2020) y de manera cada vez más ascendente se asignó a la aptitud del suelo, otorgando mayor puntuación a las condiciones

de mayor humedad relativa. La temperatura es crítica para el crecimiento de la naranja porque está relacionada con las etapas fenológicas de la planta, por ejemplo, floración, fructificación y maduración. Las temperaturas mínimas y máximas extremas pueden ser factores limitantes para la producción de naranja porque pueden provocar la caída de las flores. Por lo tanto, los límites extremos de temperatura en el área de estudio se asignaron a la aptitud moderada y baja del suelo para el crecimiento de naranja, y la porción templada del área de estudio, distribuida en el centro del acuífero, se asignó a puntuaciones más altas de aptitud del suelo. En el área de estudio, la temperatura media mínima varía de 11.2°C a 14.7°C, y la temperatura media máxima fluctúa de 25.9°C a 30°C, por lo tanto, dichos valores se encuentran dentro del rango óptimo para la producción de naranja, que se encuentra entre 24°C y 32°C (Zabihi *et al.*, 2015). Los naranjos en el área de estudio dependen tanto de las precipitaciones como del agua subterránea. La variabilidad anual de las precipitaciones influye fuertemente en la disponibilidad de agua durante todo el año. En verano, los naranjos se riegan naturalmente con las lluvias, pero cuando la escasez de agua se agrava, el agua subterránea obtenida de los pozos se utiliza para satisfacer las necesidades hídricas de los árboles. La precipitación media anual en el área de estudio oscila entre 293 y 683 mm y se distribuye espacialmente siguiendo un gradiente de noreste a suroeste. Este subcriterio se dividió en tres clases simétricas, otorgando una puntuación más alta a las condiciones de mayor precipitación.

La producción de naranja en la región de Rioverde depende en gran medida del riego (Charcas-Salazar *et al.*, 2002). La proximidad a las fuentes de agua es un indicador de la accesibilidad al agua. Si un huerto de naranjos se cultiva más cerca de un río, manantial o pozo, se puede asegurar la producción de frutos (Doorembos y Kassam, 1979; Steduto, 2012). Por lo tanto, para tener en cuenta la proximidad a las fuentes de agua, calculamos tres subcriterios: distancia a los ríos, distancia a los manantiales y distancia a los pozos. El fundamento utilizado para asignar puntuaciones de aptitud del suelo a los subcriterios relacionados con la proximidad a las fuentes de agua fue el sistema utilizado para la extracción y distribución del agua. En el caso de los ríos y pozos, el agua se extrae y distribuye mediante sistemas de bombeo que requieren electricidad, lo que se vuelve costoso a medida que aumenta la distancia (Cengiz y Akbulak, 2009).

**Cuadro 1.** Valores de estandarización para subcriterios y valores de ponderación asignados.

<b>Criterio</b>	<b>Subcriterio</b>	<b>Rango de valores</b>	<b>Aptitud de del suelo</b>	<b>Valores estandarizados</b>	<b>Área (%)</b>	<b>Peso</b>
Topografía	Elevación (m.s.n.m.)	700-900	Alta	4	67.26	0.0487
		900-1100	Moderada	3	0.28	
		1100-1500	Baja	2	28.28	
		>1500	Exclusión	1	4.19	
	Pendiente (%)	0-10	Alta	4	70.11	0.0137
		0-20	Moderada	3	8.45	
		20-25	Baja	2	3.55	
		>25	Exclusión	1	17.89	
	Aspecto de la pendiente (categórica)	Plano, Sur Sureste, Suroeste	Alta	4	43.59	0.0477
			Moderada	3	16.89	
		Este, Oeste Norte, Noreste, Noroeste	Baja	2	17.31	
			Exclusión	1	22.21	
Suelo	pH (adimensional)	6.0-7.0	Alta	4	11.88	0.1188
		7.0-7.5	Moderada	3	27.21	
		7.5-8	Baja	2	36.41	
		>8	Exclusión	1	24.51	
	Profundidad de suelo (cm)	0-50	Exclusión	1	8.10	0.1629
		50-80	Baja	2	32.34	
		80-100	Moderada	3	34.66	
		>100	Alta	4	24.91	
	Conductividad eléctrica dS/m	0-1.7	Alta	4	66.36	0.0927
		1.7-2.3	Moderada	3	16.72	
		2.3-3.3	Baja	2	10.78	
		>3.3	Exclusión	1	6.14	
	Textura del suelo (categórica)	Fino	Alta	4	77.87	0.0395
		Medio	Baja	3	21.76	
		Grueso	Exclusión	1	0.37	

**Cuadro 1.** (Continuación) Valores de estandarización para subcriterios y valores de ponderación asignados.

<b>Criterio</b>	<b>Subcriterio</b>	<b>Rango de valores</b>	<b>Aptitud del suelo</b>	<b>Valores estandarizados</b>	<b>Área (%)</b>	<b>Peso</b>
Climáticos	Humedad relativa (%)	59-63	Exclusión	1	0.50	0.0232
		63-65	Baja	2	4.22	
		65-68	Moderada	3	33.10	
		>68	Alta	4	62.17	
	Temperatura media mínima (° C)	11.2-12.5	Baja	2	15.73	0.0516
		12.5-13	Moderada	3	20.95	
		>13	Alta	4	63.32	
	Temperatura media máxima (° C)	>29	Moderada	3	21.62	0.1036
		29-29.5	Alta	4	55.81	
		>29.5	Baja	2	22.56	
	Precipitación (mm)	0-500	Baja	2	54.91	0.1819
		500-600	Moderada	3	24.51	
>600		Alta	4	20.58		
Proximidad a fuentes de agua	Distancia a ríos y arroyos (km)	0-1	Alta	4	26.58	0.0275
		1.0-2.0	Moderada	3	41.90	
		3.0-5.0	Baja	2	22.87	
		>5	Exclusión	1	8.65	
	Distancia a pozos (km)	0-0.5	Alta	4	10.75	0.0678
		0.5-1.0	Moderada	3	9.61	
		1.0-2.0	Baja	2	9.26	
		>2.0	Exclusión	1	70.38	
	Distancia a manantiales (km)	0-2	Alta	4	5.90	0.0111
		2-0-4.0	Moderada	3	10.80	
		4.0-6.0	Baja	2	13.84	
		>6	Exclusión	1	69.46	

En el caso de los manantiales, el agua simplemente se canaliza a través de canales contruidos con hormigón, por tanto, el líquido puede recorrer distancias más largas sin costes adicionales. Por esta razón, los rangos de distancia asignados a puntuaciones más altas de aptitud del suelo son más cortos en el caso de los subcriterios de distancia a ríos y pozos, ya que se requiere electricidad para hacer funcionar el sistema de bombeo.

### **Proceso de Jerarquía Analítica**

El proceso de jerarquía analítica (AHP) es un enfoque ampliamente utilizado y diseñado para encontrar una puntuación integradora que califique una característica con base en ciertos criterios/subcriterios (factor/subfactor), por ejemplo, para el caso espacial, puede usarse para determinar la aptitud del suelo. Consiste en obtener pesos para cada criterio o factor a partir del cálculo del vector propio de la matriz de comparación por pares que utiliza la escala de 9 puntos de Saaty (2004). Para recabar la opinión de expertos sobre el cultivo de cítricos, se realizó una encuesta entre cinco expertos del Instituto Nacional de Investigaciones Agrícolas Forestales y Pecuarias de México. La encuesta tuvo como objetivo priorizar factores y subfactores para calcular ponderaciones para estandarizar las puntuaciones originales de las variables ambientales.

En esta investigación se utilizaron dos tipos de matrices de comparación por pares: 1) una matriz de comparación dentro de criterios y 2) una matriz de comparación entre criterios. En la matriz de comparación dentro de criterios se construyeron cuatro matrices (Cuadro 2). En la matriz de comparación entre criterios solo se creó una matriz (Cuadro 3). Como medida del grado de consistencia para cada matriz de comparación por pares, se utilizó un índice de consistencia (CR) inferior a 0,1. El Cuadro 4 muestra los pesos calculados para cada matriz de comparación por pares. La suma de las ponderaciones de cada subcriterio es igual a 1, y lo mismo se aplica a las ponderaciones de cada criterio (Rahman y Saha, 2008; Cengiz y Akbulak, 2009; Tercan y Dereli, 2020).



**Cuadro 2.** Matrices de comparación por pares dentro de criterios.

**Criterio: Topografía**

	Elevación	Pendiente	Aspecto
Elevación	1		
Pendiente	1/3	1	
Aspecto	1	5	1

C.R. = 0.03

**Criterio: Suelo**

	pH	Profundidad de suelo	Textura del suelo	Conductividad eléctrica
pH	1			
Profundidad de suelo	3	1		
Textura del suelo	3	1	1	
Conductividad eléctrica	3	1/3	1	1

C.R. = 0.06

**Criterio: Clima**

	Humedad relativa	temperatura media mínima	temperatura media máxima	Precipitación
Humedad relativa	1			
Temperatura media mínima	3	1		
Temperatura media máxima	5	3	1	
Precipitación	5	3	3	1

C.R. = 0.07

**Criterio: Proximidad a fuentes de agua**

	Distancia a ríos	Distancia a pozos	Distancia a manantiales
Distancia a ríos	1		
Distancia a pozos	1/3	1	
Distancia a manantiales	3	5	1

C.R.= 0.03

**Cuadro 3.** Matrices de comparación por pares entre criterios.

**Los cuatro criterios**

	Topografía	Suelo	Proximidad a fuentes de agua	Clima
Topografía	1			
Suelo	3	1		
Proximidad a fuentes de agua	5	3	1	
Clima	5	3	3	1

C.R. = 0.01

**Cuadro 4** Ponderación de criterios y subcriterios.

Criterios principales	Peso	Subcriterios	Peso
Topografía	0.1201	Elevación	0.4054
		Pendiente	0.1140
		Aspecto	0.4806
Suelo	0.4131	pH	0.2876
		Profundidad de suelo	0.3943
		Textura del suelo	0.0956
		Conductividad eléctrica	0.2243
Clima	0.3603	Humedad relativa	0.0645
		Temperatura media mínima	0.1431
		Temperatura media máxima	0.2876
		Precipitación	0.5048
Proximidad a fuentes de agua	0.1064	Distancia a ríos	0.2583
		Distancia a pozos	0.6370
		Distancia a manantiales	0.1047
Total	-		

### Combinación Lineal Ponderada

Para combinar los subcriterios individuales en una puntuación consolidada, utilizamos el enfoque de combinación lineal ponderada (WLC, por sus siglas en inglés). Este método consiste en aplicar una ponderación a cada subcriterio/criterio y luego sumar puntuaciones parciales para obtener métricas integradas (Rahman y Saha, 2008; Zolekar y Bhagat, 2015). La ecuación general de WLC es la siguiente:

$$LS = \sum w_i x_i \quad (1)$$

donde LS es la aptitud del suelo para el cultivo de naranjos,  $w_i$  es el peso del criterio/subcriterio  $i$  y  $x_i$  es la puntuación estandarizada del criterio/subcriterio  $i$ . El Cuadro 5 muestra las ecuaciones utilizadas para determinar la aptitud del suelo según cada criterio, es decir, topografía, suelo, clima y proximidad a fuentes de agua.

**Cuadro 5.** Ecuaciones utilizadas para determinar la aptitud del suelo mediante subcriterios para el cultivo de naranjos en Rioverde, México.

Criterios	Subcriterio 1	Subcriterio 2	Subcriterio 3	Subcriterio 4
LS.topografía =	Elevación x 0.4054	+ Pendiente x 0.1140	+ Aspecto x 0.4806	
LS.suelo =	pH x 0.2876	+ Profundidad de suelo x 0.3943	+ Textura de suelo x 0.0956	+ Conductividad eléctrica x 0.2243
LS.clima =	Humedad relativa x 0.0645	+ Temperatura media mínima x 0.1431	+ Temperatura media máxima x 0.2876	+ Precipitación x 0.5048
LS.proximidad =	Distancia a ríos x 0.2583	+ Distancia a pozos x 0.6370	+ Distancia a manantiales x 0.1047	

LS.topografía: Aptitud del suelo para el criterio topografía, LS.suelo: Aptitud del suelo para el criterio suelo, LS.clima: Aptitud del suelo para el criterio climático y LS.proximidad: Aptitud del suelo para el criterio de proximidad.

El Cuadro 6 presenta la ecuación utilizada para determinar la aptitud general del suelo considerando todos los criterios. Los valores de LS se agruparon en cuatro clases, es decir, exclusión (0 – 1), baja (1 – 2), moderada (2 – 3) y alta (3 – 4).

**Cuadro 6.** Ecuación utilizada para determinar la aptitud final del suelo para el cultivo de naranja en Rioverde, México.

<b>Aptitud del suelo</b>	<b>Criterio 1</b>	<b>Criterio 2</b>	<b>Criterio 3</b>	<b>Criterio 4</b>
LS.naranjos =	LS.topografía x 0.1201	+ LS.suelo x 0.4131	+ LS.clima x 0.3603	+ LS.proximidad x 0.1064

### **Análisis de Componentes Principales Para Determinar la Aptitud del Suelo Durante Varios Años**

El análisis de componentes principales construye un nuevo conjunto de variables no correlacionadas llamadas "componentes principales" (PCs), que son combinaciones lineales de las variables originales que captan secuencialmente la máxima variabilidad del conjunto de datos inicial, lo que lleva a una pérdida mínima de información. Dado que los PC son ortogonales entre sí y no están correlacionados, no contienen información redundante y pueden analizarse de forma independiente (Lasaponara, 2006; Lanorte *et al.*, 2015; Miranda-Aragón *et al.*, 2012). Estas poderosas características los convierten en una herramienta ideal para descomponer un problema complejo en uno simple.

Para extraer los PC del conjunto de datos, primero se calcula la matriz de covarianza (**S**) con la siguiente ecuación (Díaz Monroy, 2007):

$$\mathbf{S} = \frac{1}{n} \mathbf{X}' (\mathbf{I}_n - \frac{1}{n} \mathbf{1}' \mathbf{1}) \mathbf{X} \quad (2)$$

Donde  $\mathbf{X} = \{LS_1, LS_2, LS_3, \dots, LS_{20}\}$ , y  $LS_1$  son la aptitud del suelo del primer año correspondiente al 2000, y  $LS_2$  corresponde a la aptitud del suelo del segundo año correspondiente al 2001.  $LS_{20}$  corresponde a la aptitud del suelo para el año 20, es decir, 2019.  $\mathbf{I}_n = n \times n$  matriz identidad,  $\mathbf{1} = 1 \times n$  vector de todos,  $\mathbf{1}'$  corresponde a la transposición de  $\mathbf{1}$ , y  $n$  corresponde al número total de observaciones (píxeles).

Los valores propios  $(\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_{20})$  representan la variabilidad de cada componente. Se obtuvieron generando la diagonal de la matriz de varianza-covarianza ( $S$ ) de la forma  $\Gamma\Lambda\Gamma'$ . La matriz  $n \times n$   $\Lambda$  contiene  $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_{20}$  en la diagonal. La matriz  $n \times n$   $\Gamma$  contiene vectores propios  $u_1, u_2, u_3, \dots, u_{20}$  en las columnas, es decir,  $u'_1 = (u_{1,1}, u_{2,1}, u_{3,1}, \dots, u_{20,1})$ . Estos son los coeficientes utilizados para la combinación lineal para calcular cada PC. Estos vectores propios representan un nuevo conjunto de fuentes de variación no correlacionadas.

Debido a que el primer PC captura la mayor variabilidad del conjunto de datos original, se utilizó para fusionar los 20 mapas de aptitud del suelo ( $LS_1, LS_2, LS_3, \dots, LS_{20}$ ) en un mapa integrado de aptitud del suelo ( $PC_1$ ), incluyendo la variabilidad espacial causada por la variación anual en la precipitación. Por lo tanto, el primer componente principal ( $PC_1$ ) se obtuvo de la siguiente manera, de aquí en adelante mencionado como el mapa de aptitud del suelo basado en PCA:

$$PC_1 = \sum_{i=1}^{20} LS_i \cdot u_{i,1} \quad (3)$$

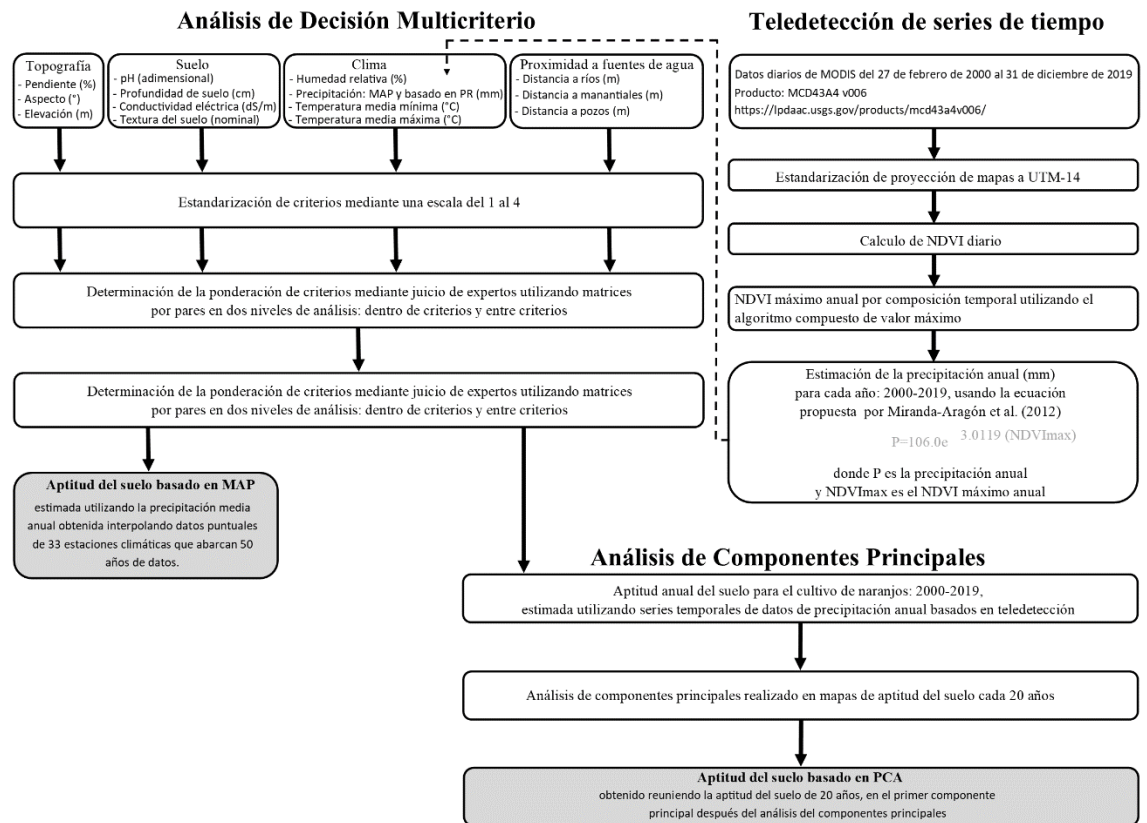
La correlación entre la  $i$ -ésima variable original  $LS_i$  y el  $j$ -ésimo componente principal  $PC_j$  se puede calcular de la siguiente manera:

$$Corr (LS_i, PC_j) = Var(LS_i)^{-1/2} \cdot \lambda_j^{-1/2} \cdot \sum_{k=1}^{20} Cov(LS_i, LS_k) \cdot u_{k,j} \quad (4)$$

### **Aptitud Estimada del Suelo vs Distribución Espacial Actual de los Naranjos**

Para tener métricas con fines de validación de mapas de aptitud del suelo, las comparamos con la distribución espacial actual de los naranjales. La base de datos espacial de naranjos se obtuvo de CESAVESLP (2022) en formato polígono. Contiene un total de 2,234 arboledas en toda el área de estudio y se consideró suelo apto verdadero. El límite de las huertas de naranja se cruzó con los mapas de aptitud del suelo basados en MAP y

PCA previamente vectorizados. MAP significa Precipitación Anual Media. La aptitud moderada y alta del suelo de ambos mapas se consideraron estimaciones válidas de la aptitud del suelo. La Figura 3 muestra el diagrama de flujo de la metodología integrada para obtener los mapas de aptitud del suelo basados en MAP y PCA.



**Figura 3.** Diagrama de flujo utilizado en la metodología

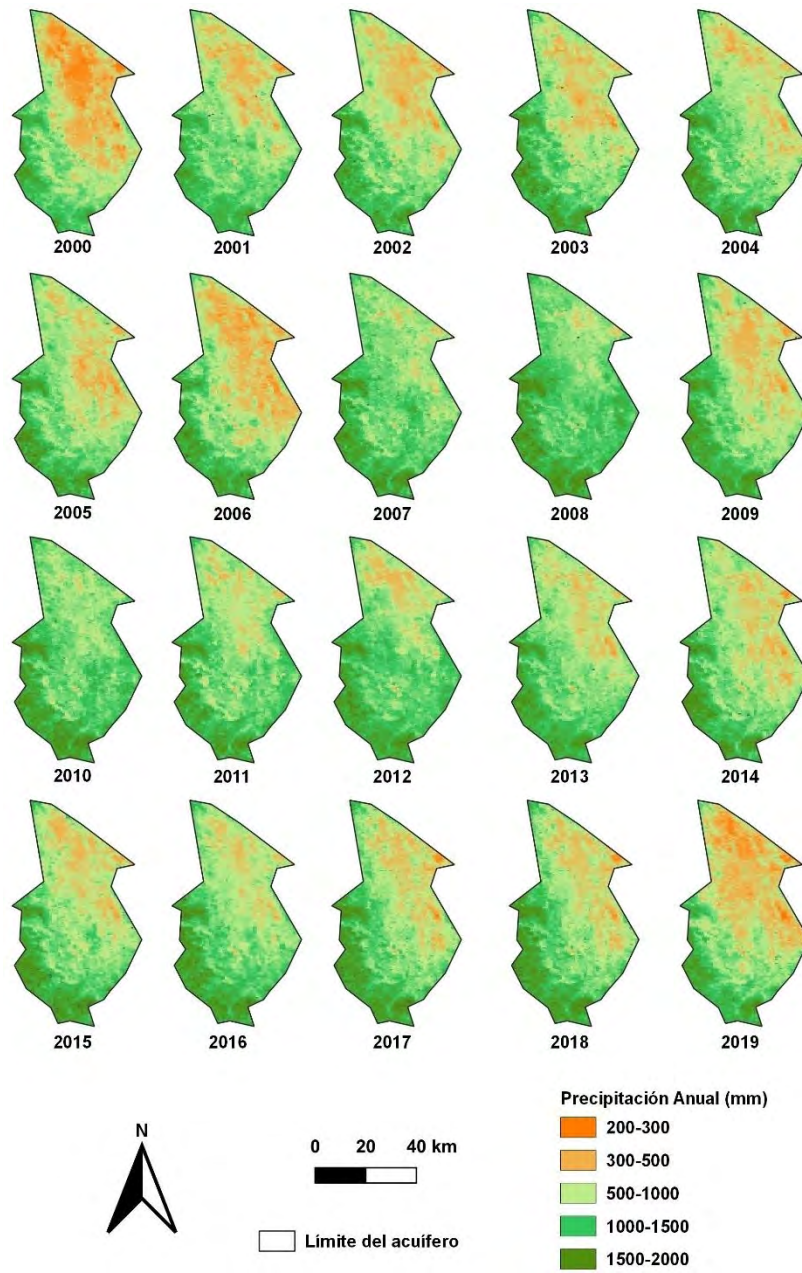
## **RESULTADOS**

### **Variación Espaciotemporal de la Precipitación**

La Figura 4 muestra el patrón de precipitación estimado en el área de estudio, delimitada por el límite del acuífero, para los años 2000-2019, calculado utilizando el compuesto temporal del NDVI máximo anual, construido con datos diarios de detección remota. Al analizar la Figura 4 se pueden observar dos patrones temporales. El primer patrón puede considerarse de 2000 a 2006, mientras que el segundo patrón puede verse de 2011 a 2019. Los años 2007, 2008 y 2010 fueron años más húmedos, aunque 2009 fue un año más seco. En general, las regiones norte y media del área de estudio, con un patrón espacial de noroeste a centro-este, han sido las más afectadas por la escasez de agua, experimentando precipitaciones inferiores a 500 mm.

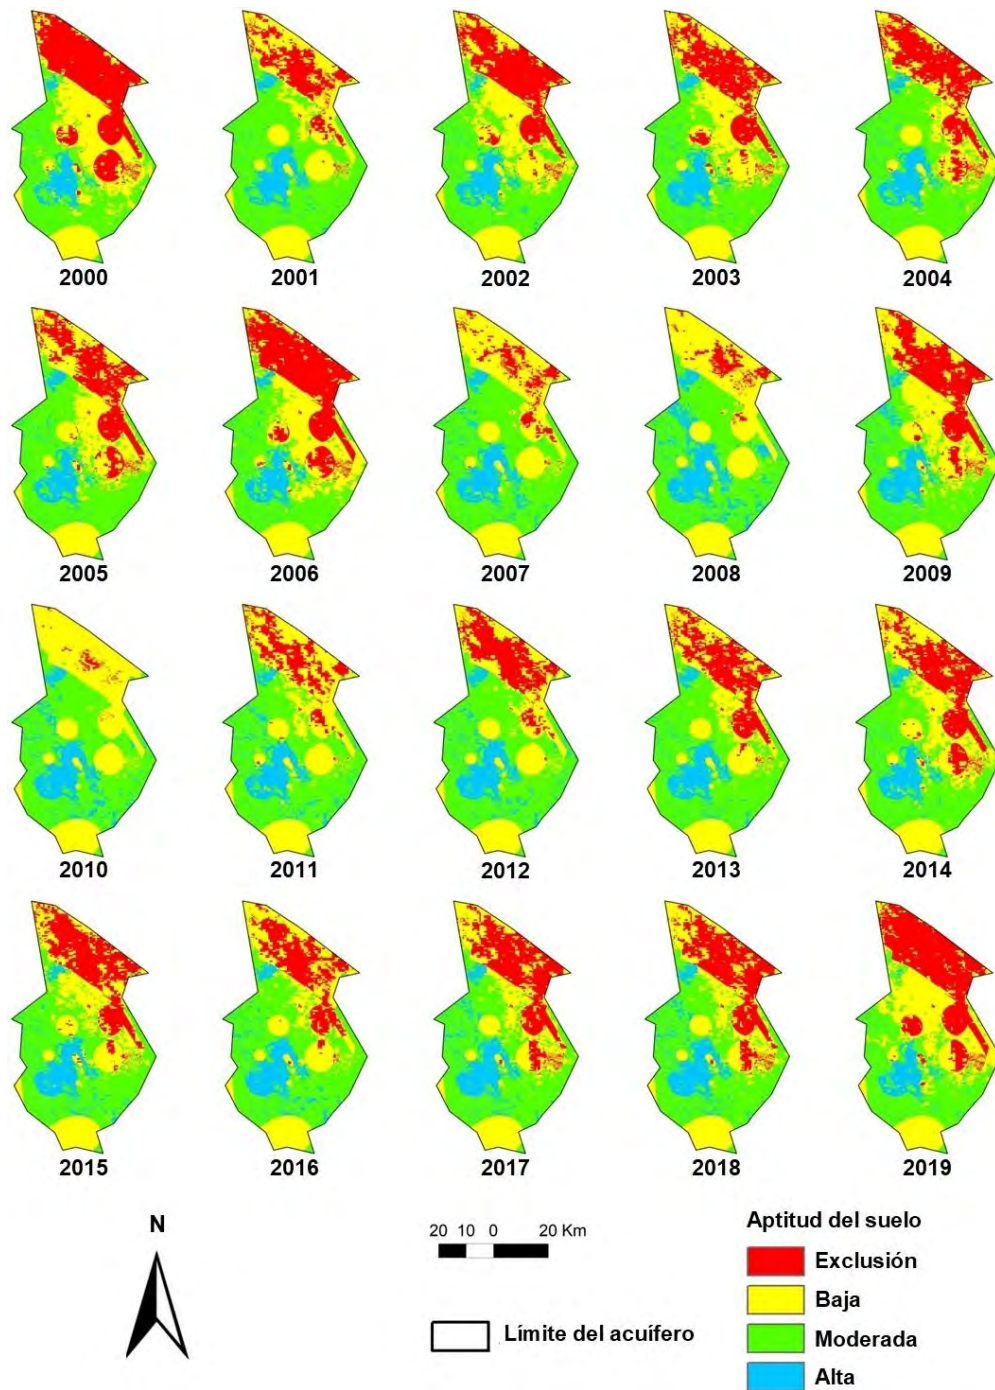
### **Patrón Espacial de Aptitud Anual del Suelo Para el Cultivo de Naranjos**

La Figura 5 revela el patrón espaciotemporal de aptitud del suelo para el cultivo de naranjos en la región de Rioverde para cada año, con énfasis en la variabilidad anual de la precipitación. Este patrón espacial de aptitud del suelo está fuertemente influenciado por las precipitaciones anuales. Se pueden identificar dos áreas de alta aptitud del suelo para el cultivo de naranjos. La primera porción de terreno está en la porción centro-sur del área de estudio y se puede distinguir como el área más grande de alta aptitud del suelo (en azul), mientras que una pequeña porción de suelo también se exhibe hacia la dirección noroeste del área de estudio.



**Figura 4.** Distribución espaciotemporal de la precipitación anual basada en sensores remotos construida con datos diarios del NDVI en el área de estudio.





**Figura 5.** Aptitud del suelo para huertos de naranjos estimada mediante el uso de precipitación anual basada en sensores remotos para cada año: 2000-2019.

## **Análisis de Componentes Principales**

El Cuadro 7 presenta los coeficientes obtenidos para cada componente principal con base en la aptitud anual del suelo para el cultivo de naranjos en la región de Rioverde. El primer componente principal capturó el 99,62% de la varianza asociada a la distribución espacial de la aptitud del suelo de naranjales respecto del comportamiento espaciotemporal de la precipitación anual en el área de estudio, es decir, el primer componente incorporó eficientemente la distribución espacial y temporal de cada mapa anual de aptitud del suelo calculado utilizando la precipitación anual basada en el NDVI. De hecho, los coeficientes y cargas calculados para el primer componente principal fueron los mismos (0,22 y 0,99, respectivamente) (Cuadro 7 y Cuadro 8). Revela que todos los años estuvieron representados exitosamente por el primer componente principal, por lo tanto, capturó detalles profundos de todos los componentes principales en el primero.

**Cuadro 7.** Matriz de valores propios, vectores propios y varianza explicada obtenida del análisis de componentes principales ejecutado para integrar los valores anuales de aptitud del suelo en un mapa de aptitud del suelo homogéneo basado en PCA, es decir, mapa PC1.

PC's	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10	PC11	PC12	PC13	PC14	PC15	PC16	PC17	PC18	PC19	PC20
% Varianza explicada	99.62	0.09	0.04	0.03	0.03	0.02	0.02	0.02	0.02	0.02	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.00	0.00
Valor propio	19.92	0.02	0.01	0.01	0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
V. propio 1 (Año 2000)	0.22	-0.21	-0.36	0.22	-0.59	0.56	-0.18	0.04	-0.03	0.13	-0.05	0.00	0.01	0.02	-0.01	-0.10	0.00	-0.03	-0.01	0.00
V. propio 2 (Año 2001)	0.22	0.15	0.11	-0.15	0.09	0.07	-0.07	0.12	-0.20	0.06	-0.17	0.01	-0.07	-0.20	0.52	-0.46	-0.47	0.18	0.01	0.00
V. propio 3 (Año 2002)	0.22	-0.17	-0.07	-0.29	0.06	0.11	0.33	0.26	-0.29	-0.11	-0.05	0.53	0.04	-0.43	-0.19	0.13	0.16	0.00	0.00	0.00
V. propio 4 (Año 2003)	0.22	-0.05	-0.04	-0.41	-0.09	0.00	0.04	0.56	0.08	-0.27	0.19	-0.35	-0.28	0.32	-0.10	0.11	-0.13	-0.02	0.00	0.00
V. propio 5 (Año 2004)	0.22	-0.12	0.05	-0.10	0.12	-0.12	-0.53	-0.16	-0.47	0.10	0.46	0.22	0.00	0.27	-0.11	-0.04	0.04	0.10	-0.02	0.00
V. propio 6 (Año 2005)	0.22	-0.05	-0.11	-0.31	-0.19	-0.29	-0.12	-0.12	0.66	0.17	0.27	0.16	0.08	-0.25	-0.02	-0.22	0.04	0.07	-0.01	0.00
V. propio 7 (Año 2006)	0.22	-0.30	-0.28	0.16	0.11	-0.25	-0.27	-0.23	0.00	-0.63	-0.23	-0.14	-0.12	-0.24	0.07	0.05	-0.01	-0.02	0.00	0.00
V. propio 8 (Año 2007)	0.22	0.30	-0.02	0.02	0.00	-0.11	-0.05	-0.04	-0.06	0.12	-0.05	0.07	-0.27	-0.04	-0.01	-0.06	0.00	-0.86	0.04	0.00
V. propio 9 (Año 2008)	0.22	0.42	-0.12	0.14	-0.06	-0.10	0.05	-0.05	0.00	0.03	-0.07	0.07	-0.25	0.02	-0.07	0.17	0.03	0.27	-0.74	0.00
V. propio 10 (Año 2009)	0.22	-0.17	0.06	-0.27	-0.11	-0.07	0.17	-0.29	0.09	0.00	-0.46	0.31	0.09	0.59	0.14	0.12	-0.08	-0.02	0.02	0.00
V. propio 11 (Año 2010)	0.22	0.41	-0.15	0.18	-0.08	-0.11	0.09	-0.07	-0.02	0.04	-0.02	0.08	-0.29	0.02	-0.12	0.14	0.01	0.35	0.67	0.00
V. propio 12 (Año 2011)	0.22	0.35	-0.12	0.07	0.05	0.09	0.23	-0.08	-0.03	-0.38	0.15	-0.05	0.57	0.18	-0.23	-0.39	-0.01	-0.06	-0.01	0.00
V. propio 13 (Año 2012)	0.22	0.23	-0.04	0.00	0.12	0.09	-0.26	0.19	0.10	0.05	0.02	-0.04	0.49	-0.08	0.38	0.60	0.03	-0.06	0.06	0.00
V. propio 14 (Año 2013)	0.22	-0.04	0.20	-0.07	0.19	0.08	-0.24	0.00	0.05	0.26	-0.39	-0.24	0.14	-0.15	-0.63	0.04	-0.29	0.05	0.01	0.00
V. propio 15 (Año 2014)	0.22	-0.11	0.06	-0.18	-0.27	-0.17	0.37	-0.38	-0.33	0.20	0.15	-0.51	0.10	-0.19	0.10	0.15	0.04	0.00	-0.01	0.00
V. propio 16 (Año 2015)	0.22	-0.08	0.20	0.02	0.39	0.58	0.16	-0.36	0.26	-0.10	0.30	0.00	-0.27	-0.02	0.06	0.12	-0.08	-0.01	-0.01	0.00
V. propio 17 (Año 2016)	0.22	0.05	0.21	-0.09	0.13	0.11	-0.12	0.08	0.02	0.06	-0.25	-0.20	-0.06	0.03	0.12	-0.27	0.79	0.09	0.03	0.00
V. propio 18 (Año 2017)	0.22	-0.15	0.43	0.37	-0.16	-0.15	0.08	0.17	0.06	-0.06	0.07	0.08	0.03	0.00	0.02	0.00	-0.04	-0.01	0.00	-0.71
V. propio 19 (Año 2018)	0.22	-0.15	0.43	0.37	-0.16	-0.15	0.08	0.17	0.06	-0.06	0.07	0.08	0.03	0.00	0.02	0.00	-0.04	-0.01	-0.01	0.71
V. propio 20 (Año 2019)	0.22	-0.31	-0.45	0.31	0.46	-0.17	0.26	0.20	0.04	0.40	0.04	-0.08	0.03	0.17	0.07	-0.10	0.00	0.00	-0.02	0.00

**Cuadro 8.** Matriz de cargas para componentes principales.

	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
Carga Año 2000	0.9972	-0.0283	-0.0313	0.0160	-0.0422	0.0394	-0.0114	0.0025	-0.0018	0.0075
Carga Año 2001	0.9986	0.0207	0.0095	-0.0110	0.0065	0.0049	-0.0042	0.0075	-0.0116	0.0035
Carga Año 2002	0.9982	-0.0231	-0.0061	-0.0208	0.0046	0.0077	0.0209	0.0156	-0.0170	-0.0059
Carga Año 2003	0.9983	-0.0066	-0.0039	-0.0296	-0.0062	0.0000	0.0028	0.0337	0.0048	-0.0152
Carga Año 2004	0.9983	-0.0164	0.0045	-0.0071	0.0084	-0.0084	-0.0337	-0.0095	-0.0274	0.0055
Carga Año 2005	0.9982	-0.0070	-0.0094	-0.0227	-0.0134	-0.0207	-0.0077	-0.0070	0.0385	0.0095
Carga Año 2006	0.9975	-0.0417	-0.0243	0.0114	0.0077	-0.0174	-0.0169	-0.0140	0.0000	-0.0353
Carga Año 2007	0.9985	0.0411	-0.0019	0.0016	-0.0002	-0.0075	-0.0032	-0.0026	-0.0034	0.0068
Carga Año 2008	0.9978	0.0573	-0.0103	0.0102	-0.0046	-0.0068	0.0029	-0.0028	-0.0002	0.0019
Carga Año 2009	0.9983	-0.0239	0.0052	-0.0195	-0.0076	-0.0052	0.0106	-0.0178	0.0054	0.0003
Carga Año 2010	0.9977	0.0567	-0.0129	0.0130	-0.0055	-0.0079	0.0056	-0.0044	-0.0009	0.0021
Carga Año 2011	0.9976	0.0480	-0.0104	0.0052	0.0039	0.0063	0.0145	-0.0051	-0.0018	-0.0214
Carga Año 2012	0.9983	0.0316	-0.0037	-0.0003	0.0083	0.0065	-0.0165	0.0112	0.0060	0.0027
Carga Año 2013	0.9986	-0.0061	0.0175	-0.0050	0.0132	0.0057	-0.0151	-0.0001	0.0032	0.0143
Carga Año 2014	0.9982	-0.0155	0.0056	-0.0132	-0.0189	-0.0122	0.0235	-0.0228	-0.0195	0.0109
Carga Año 2015	0.9979	-0.0109	0.0174	0.0014	0.0275	0.0405	0.0101	-0.0220	0.0155	-0.0054
Carga Año 2016	0.9988	0.0067	0.0186	-0.0067	0.0090	0.0078	-0.0078	0.0051	0.0011	0.0033
Carga Año 2017	0.9985	-0.0202	0.0375	0.0272	-0.0115	-0.0102	0.0048	0.0101	0.0035	-0.0035
Carga Año 2018	0.9985	-0.0202	0.0375	0.0273	-0.0115	-0.0103	0.0048	0.0101	0.0035	-0.0035
Carga Año 2019	0.9970	-0.0424	-0.0391	0.0228	0.0326	-0.0122	0.0163	0.0123	0.0024	0.0220

**Cuadro 8. (Continuación) Matriz de cargas para componentes principales.**

	PC11	PC12	PC13	PC14	PC15	PC16	PC17	PC18	PC19	PC20
Carga Año 2000	-0.0025	-0.0001	0.0004	0.0008	-0.0005	-0.0046	0.0001	-0.0011	-0.0002	0.0000
Carga Año 2001	-0.0092	0.0006	-0.0035	-0.0103	0.0253	-0.0221	-0.0213	0.0067	0.0002	0.0000
Carga Año 2002	-0.0025	0.0286	0.0023	-0.0223	-0.0090	0.0061	0.0072	0.0001	-0.0001	0.0000
Carga Año 2003	0.0105	-0.0191	-0.0151	0.0165	-0.0047	0.0051	-0.0057	-0.0006	0.0001	0.0000
Carga Año 2004	0.0251	0.0120	0.0002	0.0138	-0.0054	-0.0017	0.0017	0.0035	-0.0005	0.0000
Carga Año 2005	0.0150	0.0088	0.0044	-0.0131	-0.0009	-0.0103	0.0016	0.0024	-0.0003	0.0000
Carga Año 2006	-0.0128	-0.0076	-0.0065	-0.0123	0.0036	0.0024	-0.0002	-0.0008	0.0001	0.0000
Carga Año 2007	-0.0025	0.0039	-0.0144	-0.0022	-0.0007	-0.0028	-0.0002	-0.0317	0.0011	0.0000
Carga Año 2008	-0.0040	0.0038	-0.0133	0.0009	-0.0035	0.0079	0.0013	0.0099	-0.0198	0.0000
Carga Año 2009	-0.0253	0.0167	0.0047	0.0304	0.0067	0.0058	-0.0037	-0.0006	0.0006	0.0000
Carga Año 2010	-0.0009	0.0044	-0.0158	0.0009	-0.0057	0.0066	0.0006	0.0129	0.0178	0.0000
Carga Año 2011	0.0083	-0.0029	0.0306	0.0092	-0.0113	-0.0185	-0.0004	-0.0021	-0.0002	0.0000
Carga Año 2012	0.0010	-0.0024	0.0263	-0.0041	0.0185	0.0284	0.0012	-0.0024	0.0016	0.0000
Carga Año 2013	-0.0216	-0.0129	0.0073	-0.0078	-0.0305	0.0021	-0.0129	0.0018	0.0003	0.0000
Carga Año 2014	0.0084	-0.0277	0.0052	-0.0100	0.0047	0.0073	0.0017	-0.0001	-0.0003	0.0000
Carga Año 2015	0.0165	0.0000	-0.0145	-0.0010	0.0028	0.0056	-0.0035	-0.0003	-0.0003	0.0000
Carga Año 2016	-0.0138	-0.0108	-0.0035	0.0017	0.0058	-0.0130	0.0358	0.0034	0.0007	0.0000
Carga Año 2017	0.0041	0.0044	0.0018	0.0002	0.0007	0.0002	-0.0016	-0.0004	0.0000	-0.0001
Carga Año 2018	0.0040	0.0044	0.0018	0.0002	0.0007	0.0002	-0.0016	-0.0003	-0.0002	0.0001
Carga Año 2019	0.0023	-0.0042	0.0018	0.0086	0.0032	-0.0048	-0.0001	-0.0002	-0.0006	0.0000

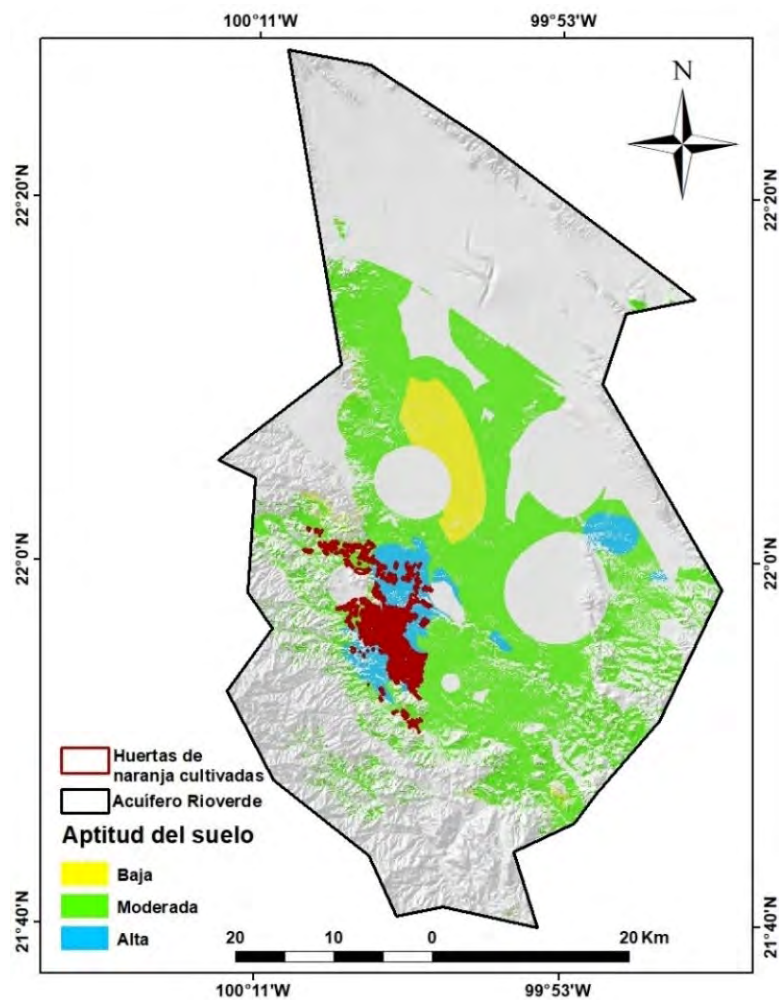
### **Aptitud Integrada del Suelo Para el Cultivo de Naranjos**

Las figuras 6 y 7 muestran la distribución espacial de los huertos de naranjos en la región de Rioverde según los enfoques de aptitud del suelo MAP y PCA, respectivamente. La aptitud del suelo basada en MAP refleja los patrones espaciales de la precipitación media anual sobre la aptitud del suelo, mientras que la aptitud del suelo basada en PCA exhibe patrones espaciales ocultos de variación interanual en la precipitación. La Figura 8 presenta una ampliación del área principal de cultivo de naranjos en el área de estudio. De acuerdo con los resultados mostrados en el Cuadro 9, el área total de suelos con aptitud alta basadas en PCA aumentó 5,392.9 ha con respecto a los suelos de aptitud alta basadas en MAP, es decir, un aumento del 52.6% el área del suelo considerado de aptitud alta.

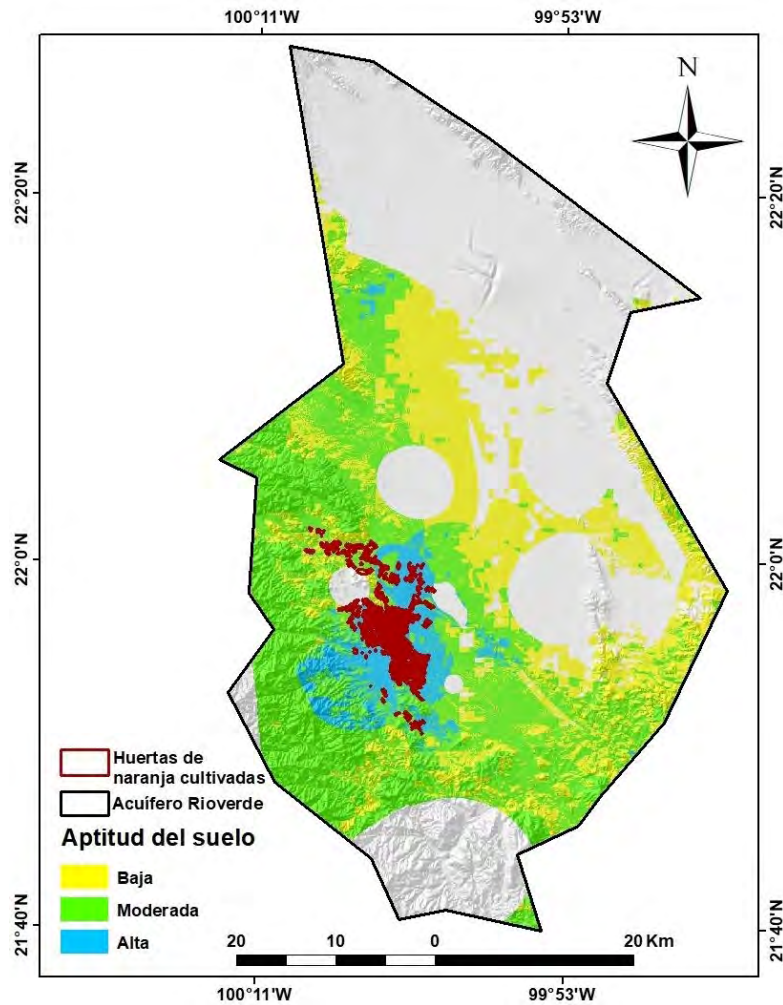
**Cuadro 9.** Aptitud estimada del suelo para huertos de naranjos en Rioverde, México.

Aptitud del suelo	Aptitud del suelo basada en MAP		Aptitud del suelo basada en PCA	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Exclusión	185986.9	66.79	126864.5	45.59
Baja	7864.1	2.85	55916.7	20.09
Moderada	74168.8	26.67	79845.7	28.69
Alta	10246.9	3.69	15639.8	5.62

MAP: Precipitación media anual, PCA: Análisis de componentes principales.



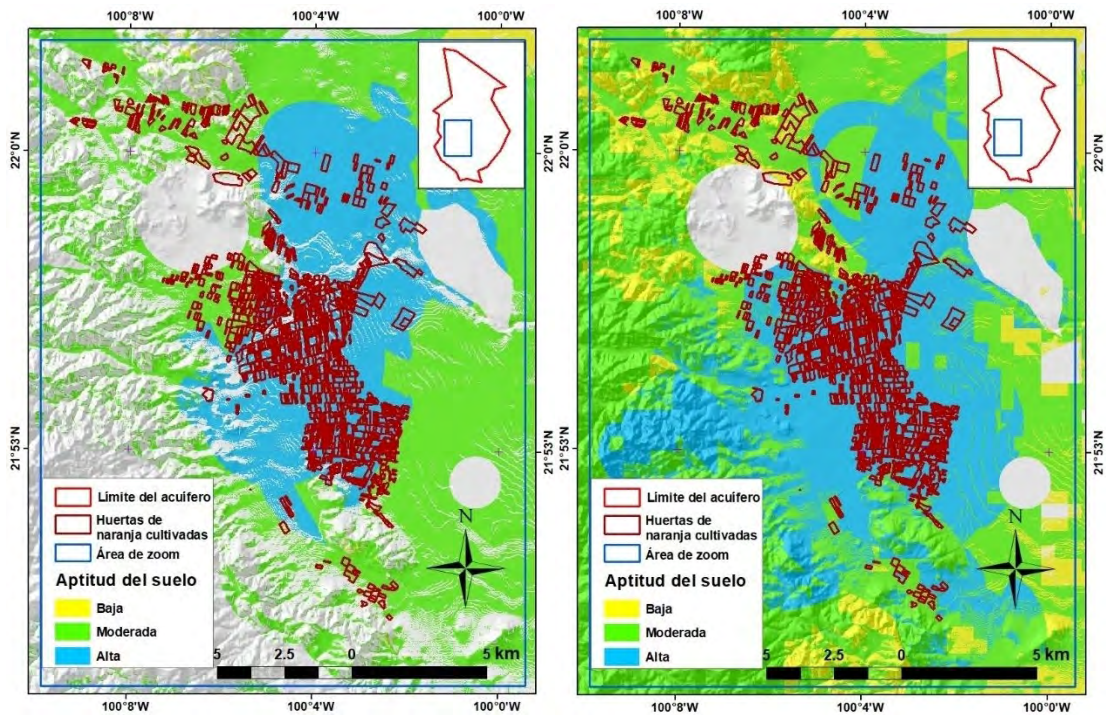
**Figura 6.** Aptitud del suelo estimada utilizando la precipitación media anual obtenida a partir de la interpolación de datos puntuales de estaciones meteorológicas.



**Figura 7.** Aptitud del suelo estimada reuniendo 20 años de datos de aptitud con análisis de componentes principales.

### **Comparación de Mapas de Aptitud del Suelo vs Distribución Espacial de Naranjos**

El Cuadro 10 presenta las comparaciones regionales de las estimaciones de aptitud del suelo basadas en MAP y PCA con el mapa actual de naranjos (reales sobre el terreno). En cuanto a la aptitud del suelo basada en el MAP, 2,294.6 ha, es decir, el 80.73% del área total de naranjos existentes, se ubicaron en zonas de aptitud media y alta dentro del área de estudio.



**Figura 8.** Zoom aplicado a los huertos de cítricos cultivados para validar la aptitud del suelo: aptitud del suelo basado en MAP (izquierda) y aptitud del suelo basado en PCA (derecha).

**Cuadro 10.** Comparación regional de la ubicación actual de los huertos de naranjos con la aptitud estimada del suelo en Rioverde, México.

Aptitud del suelo	Aptitud del suelo basada en MAP		Aptitud del suelo basada en PCA	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Exclusión	547.47	19.26	44.1	1.55
Baja	0.25	0.01	171.4	6.03
Moderada	550.46	19.37	493.7	17.37
Alta	1744.13	61.36	2133.1	75.05
Total	2842.3	100	2842.3	100

Respecto a la aptitud del suelo basada en PCA, se encontró que 2,626.8 ha, es decir, el 92.42% del área total de los actuales naranjales, se ubicaron en zonas de aptitud media y alta dentro del área de estudio.



## DISCUSIÓN

### Variación Espaciotemporal de la Precipitación

Este artículo presentó un marco metodológico para modelar la aptitud del suelo para el cultivo de naranjales en una parte de la región del cinturón de cítricos en el norte de México. Los datos de teledetección hipertemporal (diarios) fueron muy eficaces para capturar la variabilidad interanual de la precipitación a nivel de píxeles en el área de estudio. Se utilizaron datos diarios de series temporales del NDVI de veinte años para calcular el NDVI máximo anual y, por lo tanto, la precipitación anual. Se utilizó la variación espaciotemporal de la precipitación para encontrar los lugares más adecuados para el cultivo de naranjos en términos de disponibilidad de agua. Al observar el NDVI mostrado en la Figura 4, se reveló el efecto de la precipitación sobre la vegetación. Se pueden detectar tres grandes períodos de sequía: 2000-2006, 2009 único año y 2011-2019.

La teledetección hipertemporal, es decir, basada en series temporales, se ha utilizado en una variedad de condiciones o propósitos. Desde estudios mundiales hasta estudios muy locales, la teledetección hipertemporal es una herramienta estratégica para analizar una variedad de variables biofísicas, incluida la vegetación, por ejemplo, la floración de flores (Zang *et al.*, 2020), la superficie impermeable (Xu *et al.*, 2022), la temperatura superficial del suelo (Xiong *et al.*, 2022), fenología de la vegetación (Wu y Xin, 2023), etc. Dependiendo de la extensión geográfica, la resolución espacial y temporal puede verse comprometida para encontrar la mejor opción de análisis hipertemporal. En cuanto a la relación NDVI-lluvia, algunos estudios clave han documentado la relación del efecto de la lluvia sobre la vegetación (Herrmann *et al.*, 2005).

Se han reportado pocos estudios sobre el uso de datos de series temporales de sensores remotos en México. Aunque algunos estudios se han centrado en el cambio de uso de suelo o la fenología, el número de dichos estudios aún es limitado. Miranda-Aragón *et al.* (2012) realizaron un estudio que examinaba las tendencias del NDVI y las precipitaciones en un área más amplia utilizando datos de teledetección de 15 días que abarcaban una década. Nuestro estudio se basa en este trabajo utilizando la ecuación exponencial de Miranda-Aragón *et al.* (2012) para estimar la precipitación media anual a partir de datos

de series de tiempo de resolución temporal diaria que van desde el 2000 a 2019. Al comparar los datos de detección remota de ambos estudios, se encontró una fuerte correlación visual durante los primeros 11 años (2000-2010) es evidente, correspondiendo los años secos en su serie temporal a los años secos en la nuestra. Nuestro estudio se extiende a lo largo de un período más largo, que va de 2000 a 2020, y confirma que 2007, 2008 y 2010 fueron los años más húmedos del período 2000 a 2010 encontrado en el trabajo de Miranda-Aragón *et al.* (2012).

### **Patrón Espacial de Aptitud Anual del Suelo Para el Cultivo de Naranjos**

Nuestro estudio utilizó datos de teledetección de series temporales para estimar la precipitación anual, lo que nos permitió evaluar la aptitud anual del suelo para el cultivo de naranjos. Este enfoque proporcionó una perspectiva espaciotemporal de la región de Rioverde y reveló la variación en la aptitud del suelo a lo largo del tiempo. En particular, nuestros resultados indican que la parte norte del área de estudio es particularmente sensible a la variación climática, puntualmente a la variación interanual de las precipitaciones. Por otro lado, también se puede percibir una condición notable en las partes media y sur del área de estudio muestran una alta estabilidad del patrón espacial de aptitud del suelo para los naranjales (Figura 5). Ambas condiciones demuestran que el patrón temporal de aptitud del suelo en el acuífero Rioverde, nuestra área de estudio, exhibe una fuerte variación, sin embargo, en áreas específicas este patrón es relativamente homogéneo a lo largo del tiempo.

Los análisis de decisión multicriterio se emplean comúnmente para determinar la aptitud del suelo para cultivos, guiados por varios fundamentos distintos, que incluyen 1) la evaluación de una sola fecha o situación (Binte-Mostafiz *et al.*, 2021; Akhavan *et al.*, 2023), 2) análisis de sensibilidad que considera algunos criterios ambientales, por ejemplo, heladas (Elsheikh *et al.*, 2013), salinidad del suelo (Shafiezadeh *et al.*, 2018), índices climáticos (Badr *et al.*, 2018), 3) consideración de escenarios de planificación ideados por expertos en campos relevantes o partes interesadas (Corral *et al.*, 2015), 4) evaluación de los impactos de escenarios potenciales climáticos o de uso del suelo (Zabihi *et al.*, 2016), y 5) análisis de los efectos del NDVI interanual sobre la variable de respuesta,

como la aptitud del suelo (Dedeoğlu y Dengiz, 2019). Según un estudio realizado en nuestra área de investigación, la disponibilidad de agua, que está muy influenciada por la variabilidad climática, emerge como el factor más crítico, después del suelo, que afecta la producción de cultivos (Charcas-Salazar *et al.*, 2002). Por lo tanto, investigamos el impacto de la variabilidad interanual de las precipitaciones en la determinación de la aptitud del suelo para naranjales, capturando la variación de la aptitud del suelo para el período de 2000 a 2019 con una resolución temporal anual.

### **Aptitud del Suelo Integrada Para el Cultivo de Naranjos**

Las figuras 6 y 7 muestran la aptitud del suelo para el cultivo de naranjos en la región de Rioverde. El estudio analizó la distribución espacial de los huertos de naranjos en la región de Rioverde utilizando enfoques de aptitud del suelo tanto MAP como PCA. Los resultados mostraron que el enfoque basado en PCA reveló patrones espaciales ocultos de variación interanual en la precipitación, lo que llevó a un aumento del 52,6% en el área total considerada de alta aptitud del suelo en comparación con el enfoque basado en MAP. PCA y MCDA son enfoques versátiles que se han utilizado en una variedad de situaciones y contextos. Por ejemplo, Li y Yeh (2002) utilizaron PCA para reducir la dimensionalidad de las variables de distancia antes de ejecutar MCDA en una simulación del uso del suelo en Dongguan, en el sur de China. Carlón-Allende *et al.* (2009) utilizaron el análisis de componentes principales para identificar las variables más dinámicas en la regionalización hidrogeológica de cuencas en un estudio de priorización de cuencas en el lago Cuizeo, y la puntuación final para cada cuenca se obtuvo mediante el uso de técnicas de decisión multicriterio. Seyedmohammadi *et al.* (2019) utilizaron técnicas de decisión multicriterio para determinar la mejor ubicación para el cultivo de maíz, colza y soja en el norte de Irán. Se utilizó la técnica PCA para seleccionar criterios importantes para el rendimiento del cultivo. Todas las aplicaciones antes mencionadas tanto de PCA como de MCDA se han utilizado por separado o de forma complementaria. En esta investigación, se utilizó PCA para asimilar el efecto de la variabilidad interanual de la precipitación sobre la aptitud anual del suelo. Por lo tanto, la integración de los mapas anuales de aptitud del suelo generó un mapa global más completo y preciso, indicando las ventajas de utilizar PCA en los estudios de aptitud del suelo. Esto demuestra la efectividad de asimilar los efectos de

la variabilidad interanual utilizando PCA, lo que lleva a una mayor precisión y una mejor comprensión de la distribución espacial del suelo adecuado para el cultivo de naranjas en la región de Rioverde.

Los estudios también han destacado la importancia de analizar la aptitud del suelo y la productividad de los cultivos, particularmente en el contexto del cambio climático y la escasez de agua. Por ejemplo, Jayathilaka *et al.* (2012) realizaron un estudio para determinar la aptitud del suelo para cultivos de té, caucho y coco en Sri Lanka utilizando un enfoque de análisis de decisiones multicriterio. El estudio analizó datos sobre precipitaciones, humedad relativa, temperatura y evapotranspiración durante dos períodos de estudio: 1980-1992 y 1993-2007. Los autores encontraron que había una tendencia decreciente en las precipitaciones anuales en la zona húmeda, que se encuentra en el centro del país. También observaron un aumento significativo de 1,4°C en la temperatura media en todo el país. Estas condiciones climáticas cambiantes han provocado un cambio en los patrones espaciales de los cultivos en todo Sri Lanka. López-Blanco *et al.* (2018) analizaron la aptitud del suelo para el cultivo de maíz de temporal bajo proyecciones de cambio climático en México a nivel nacional. Los autores concluyeron que una reducción de las precipitaciones y un aumento de la temperatura tendrían graves implicaciones para la agricultura nacional, en particular para el maíz de secano. El estudio identificó áreas con alta estabilidad climática, así como regiones que son más vulnerables a la reducción del rendimiento del maíz en el futuro. Este estudio proporciona información sobre los impactos potenciales del cambio climático en el cultivo de maíz de secano en México.

### **Validación de Resultados**

Las estimaciones de aptitud del suelo obtenidas mediante métodos basados en MAP y PCA se compararon con la distribución espacial de 2234 huertos de naranjos como datos reales. Los resultados mostraron que ambos métodos fueron efectivos para identificar áreas con alta y media aptitud para naranjales, ya que la mayoría de los naranjales existentes se ubicaban en estas zonas. En concreto, el 80,73% de los naranjales existentes se encontraban en las zonas de alta y media aptitud ideal del suelo identificadas mediante

el método basado en MAP, mientras que el 92,42% de los naranjales existentes se encontraban en las mismas zonas según el método basado en PCA.

En el contexto del MCDA, algunos investigadores han validado sus resultados sobre la aptitud del suelo de maneras ligeramente diferentes pero interesantes. Li *et al.* (2012) validaron sus mapas de aptitud del suelo para cultivos de té en Zhejiang, China, utilizando 3745 puntos de validación obtenidos por receptores del sistema de posicionamiento global (GPS). Tras analizar las ubicaciones de cultivo de té ubicadas en regiones altamente y moderadamente adecuadas, la precisión obtenida fue del 87,91%. Dedeoğlu y Dengiz (2019) emplearon un modelo de regresión lineal simple para validar su análisis de la aptitud del suelo para el trigo. Compararon los datos de rendimiento como datos reales (variable de respuesta) con las clases de aptitud del suelo y el NDVI para garantizar la precisión. Sorprendentemente, el estudio validó con éxito el análisis al obtener coeficientes de determinación altos de 0,83 (datos de rendimiento frente a clases de aptitud del suelo) y 0,78 (datos NDVI frente a clases de aptitud del suelo). Layomi-Jayasinghe *et al.* (2019) validaron sus mapas de aptitud del suelo para cultivos de té superponiendo una capa de datos espaciales de plantaciones de té con la aptitud del suelo prevista utilizando MCDA. Su enfoque de validación implicó considerar únicamente campos agrícolas que se superponían con áreas muy adecuadas y altamente adecuadas. Sorprendentemente, este método dio como resultado una tasa de precisión del 92,46%. Otros han empleado enfoques de validación adicionales, como el trabajo de Tshabalala *et al.* (2020), quienes utilizaron la llamada característica operativa relativa bajo el marco de regresión logística. Los autores evaluaron la aptitud del suelo para el cultivo de Moringa oleifera en Sudáfrica y utilizaron regresión logística para estimar el área bajo la curva ROC, reportando una precisión del 81%.

Una perspectiva adicional para validar nuestro enfoque fue analizar el índice de consistencia (CR <0,1), que se obtuvo para matrices de comparación por pares tanto dentro de los criterios como entre criterios. Estas matrices se utilizaron para calcular las ponderaciones en el contexto del MCDA. Al examinar el índice de consistencia, podríamos medir cualquier inconsistencia en el juicio emitido por el experto y, por lo tanto, obtener más información sobre la confiabilidad de nuestro enfoque. En este sentido,

todas las matrices tuvieron valores inferiores a 0.1, es decir 0.03 para el criterio topografía, 0.06 para el criterio suelo, 0.07 para el criterio clima, 0.03 para el criterio proximidad a fuentes de agua. Finalmente, considerando los cuatro criterios, el índice de consistencia fue de 0,01 (Cengiz y Akbulak, 2009). Aunque las medidas del índice de consistencia no garantizan la precisión de nuestros resultados, pueden usarse como una señal importante de la solidez de nuestro enfoque (Rahman y Saha, 2008).

## CONCLUSIONES

Los hallazgos de esta investigación revelaron el potencial del análisis de componentes principales de datos de percepción remota de series temporales para asimilar la variación de las precipitaciones a lo largo del tiempo y luego estimar un mapa de aptitud del suelo a largo plazo para el cultivo de naranjos. La estrategia de modelado exhibió nuevas ubicaciones para cultivar cítricos para abordar el problema de la reducción del área agrícola debido al crecimiento urbano en la región de Rioverde (México), así como el efecto de la sequía recurrente en la disponibilidad de agua. Por lo tanto, utilizar sistemas de riego más eficientes, es decir, riego por goteo para producir cultivos especiales, será la mejor opción para optimizar el uso del agua. Esta metodología puede ser particularmente relevante para quienes necesitan tomar decisiones informadas sobre el uso del suelo y las estrategias de gestión del agua, especialmente en áreas propensas a la variabilidad climática y la escasez de agua. Al integrar análisis de decisiones de múltiples criterios, series de tiempo de percepción remota y análisis de componentes principales, este estudio ofrece un enfoque integral para delinear las áreas más adecuadas para la producción sostenible de cítricos en el cinturón de cítricos del norte de México. Los resultados de este estudio pueden apoyar los procesos de toma de decisiones para el manejo efectivo del suelo de los huertos de naranjos en la región de Rioverde y proporcionar información valiosa para el manejo de la producción agrícola en otras regiones semiáridas. Finalmente, el estudio demuestra que la integración de MCDA y PCA podría identificar efectivamente áreas son adecuadas para el cultivo de naranjos.

## LITERATURA CITADA

- Aguirre-Salado, C.A., Treviño-Garza, E.J., Aguirre-Calderón, O.A., Jiménez-Pérez, J., González-Tagle, M.A., Miranda-Aragón, L., Valdez-Lazalde, J.R., Aguirre-Salado, A.I. and Sánchez-Díaz, G. (2012). Forest cover mapping in North-Central Mexico: A comparison of digital image processing methods. *GIScience & Remote Sensing*, 49(6), 895–914. <https://doi.org/10.2747/1548-1603.49.6.895>.
- Akhavan, S., Jalalian, A., Toomanian, N. and Honarjo, N. (2023). Use of a GIS-based multicriteria decision-making approach, to increase accuracy in determining soil suitability, Iran. *Communications in Soil Science and Plant Analysis*, 54(5), 690–705. <https://doi.org/10.1080/00103624.2022.2118312>.
- Amini, S., Rohani, A., Aghkhani, M.H., Abbaspour-Fard, M.H. and Asgharipour, M.R. (2020). Assessment of land suitability and agricultural production sustainability using a combined approach (Fuzzy-AHP-GIS): A case study of Mazandaran province, Iran. *Information Processing in Agriculture*, 7(3), 384–402. <https://doi.org/10.1016/j.inpa.2019.10.001>.
- Anderson, C.M. (1996). Manual para productores de naranja y mandarina de la región del Río Uruguay. INTA, *Estación Experimental Agropecuaria Concordia*. <https://bit.ly/3TdN9uu>.
- Badr, G., Hoogenboom, G., Moyer, M., Keller, M., Rupp, R. and Davenport, J. (2018). Spatial suitability assessment for vineyard site selection based on fuzzy logic. *Precision Agriculture*, 19(6), 1027–1048. <https://doi.org/10.1007/s11119-018-9572-7>.
- Binte-Mostafiz, R., Noguchi, R. and Ahamed, T. (2021). Agricultural land suitability assessment using satellite remote sensing-derived soil-vegetation indices. *Land*, 10(2), 223. <https://doi.org/10.3390/land10020223>.
- Boz, A.O., Donmez, Y. and Ozyavuz, M. (2020). Use of climate maps in determining sustainable agriculture areas. *Journal of Environmental Protection and Ecology*, 21(3), 1062–1071. <http://acikerisim.nku.edu.tr/xmlui/handle/20.500.11776/4756>.
- Campos-Aranda, D.F. (2018). Comparison of the Standardized Palmer Drought Index (SPDI) in three climatic locations in San Luis Potosi, Mexico. *Tecnología y Ciencias del Agua*, 9(5), 246–279. <https://doi.org/10.24850/j-tyca-2018-05-10>.
- Carlón-Allende, T., Mendoza, M.E., López-Granados, E.M. and Morales-Manilla, L.M. (2009). Hydrogeographical regionalisation: An approach for evaluating the effects of land cover change in watersheds. A case study in the Cuitzeo lake watershed, Central Mexico. *Water Resources Management*, 23(12), 2587–2603. <https://doi.org/10.1007/s11269-008-9398-6>.

- Cengiz, T. and Akbulak, C. (2009). Application of analytical hierarchy process and geographic information systems in land-use suitability evaluation: a case study of Dümrek village (Çanakkale, Turkey). *International Journal of Sustainable Development & World Ecology*, 16(4), 286–294. <https://doi.org/10.1080/13504500903106634>.
- CESAVESLP. (2022). Datos de distribución espacial de las huertas de naranja en el Valle de Rioverde en San Luis Potosí (Mexico). *Comité Estatal de Sanidad Vegetal de San Luis Potosí (CESAVESLP)*. <http://www.cesaveslp.org.mx/>. Accessed 15 March 2022.
- Charcas-Salazar, H., Olivares-Sáenz, E. y Aguirre-Rivera, J.A. (2002). Irrigation water in Rioverde region, San Luis Potosi, Mexico. *Ingeniería Hidráulica en México*, 17(4), 37–56. <http://bit.ly/31691ew>.
- Chávez, L. (2021). Drought conditions in Mexico and its effect on agriculture (No. MX2021- 0031) (p. 11). Washington, DC.: United States Department of Agriculture, Foreign Agricultural Service, Global Agricultural Information Network. <https://bit.ly/3mQQZ08>. Accessed 15 March 2023.
- Cheng, Y., Zhang, L., Zhang, Z., Li, X., Wang, H. and Xi, X. (2022). Spatiotemporal variation and influence factors of vegetation cover in the Yellow River basin (1982–2021) Based on GIMMS NDVI and MOD13A1. *Water*, 14(20), 3274. <https://doi.org/10.3390/w14203274>.
- Cicciù, B., Schramm, F. and Schramm, V.B. (2022). Multi-criteria decision making/aid methods for assessing agricultural sustainability: a literature review. *Environmental Science & Policy*, 138, 85–96. <https://doi.org/10.1016/j.envsci.2022.09.020>.
- CONAGUA (2010). Normales climatológicas por estado (1951-2010): San Luis Potosí. Comisión Nacional del Agua. Servicio Meteorológico Nacional. <https://smn.conagua.gob.mx/es/informacion-climatologica-por-estado?estado=slp>. Accessed 24 March 2020
- CONAGUA (2015). Actualización de la disponibilidad media anual de agua en el acuífero Rio Verde (2415), Estado de San Luis Potosí. Comisión Nacional del Agua (CONAGUA), Subdirección General Técnica, Gerencia de Aguas Subterráneas, Subgerencia de Evaluación y Ordenamiento de Acuíferos. <https://bit.ly/3ZUm3dS>. Accessed 10 March 2023.
- CONAGUA (2020). Actualización de la disponibilidad media anual de agua en el acuífero Rio Verde (2415), Estado de San Luis Potosí. Comisión Nacional del Agua (CONAGUA), Subdirección General Técnica, Gerencia de Aguas Subterráneas, Subgerencia de Evaluación y Ordenamiento de Acuíferos. <https://bit.ly/3mLruh2>. Accessed 10 March 2023.



- Corner, B.R., Narayanan, R.M. and Reichenbach, S.E. (2000). Noise reduction in remote sensing imagery using data masking and principal component analysis. In A.G. Tescher (Ed.), (pp. 1–11). Presented at the International Symposium on Optical Science and Technology, San Diego, CA. <https://doi.org/10.1117/12.411533>.
- Corral, S., Legna-de la Nuez, D., Romero-Manrique. and de Lara, D. (2015). Integrated assessment of biofuel production in arid lands: Jatropha cultivation on the island of Fuerteventura. *Renewable and Sustainable Energy Reviews*, 52, 41–53. <https://doi.org/10.1016/j.rser.2015.07.070>.
- CRU (2015). Climate data. Climatic Research Unit. University of East Anglia. School of Environmental Sciences. Faculty of Science. <http://www.cru.uea.ac.uk>. Accessed 20 April 2015.
- Dalin, C., Wada, Y., Kastner, T. and Puma, M.J. (2017). Groundwater depletion embedded in international food trade. *Nature*, 543(7647), 700–704. <https://doi.org/10.1038/nature21403>.
- Dedeoğlu, M. and Dengiz, O. (2019). Generating of land suitability index for wheat with hybrid system approach using AHP and GIS. *Computers and Electronics in Agriculture*, 167, 105062. <https://doi.org/10.1016/j.compag.2019.105062>.
- Díaz Monroy, L.G. (2007). Estadística multivariada: inferencia y métodos (2. ed.). Bogotá, Colombia: Departamento de Estadística, Facultad de Ciencias, Universidad Nacional de Colombia. <https://bit.ly/3YfVP5V>.
- Díaz-Rivera, J.C. (2018). Análisis de la dinámica espacio-temporal y distribución potencial de los manantiales en el Valle de Rioverde, San Luis Potosí (Tesis de Maestría en Tecnología y Gestión del Agua). Universidad Autónoma de San Luis Potosí, Facultad de Ingeniería, San Luis Potosí, México. Retrieved from <http://bit.ly/3ZXtild>.
- Dobler-Morales, C., and Bocco, G. (2021). Social and environmental dimensions of drought in Mexico: an integrative review. *International Journal of Disaster Risk Reduction*, 55, 102067. <https://doi.org/10.1016/j.ijdrr.2021.102067>.
- DOF (2014). Agreement disclosing the technical studies of national groundwater of the Río Verde aquifer, Code 2415, in the State of San Luis Potosí, Northern Gulf administrative hydrological region - In Spanish: Acuerdo por el que se dan a conocer los estudios técnicos de aguas nacionales subterráneas del acuífero Río Verde, clave 2415, en el Estado de San Luis Potosí, región hidrológico administrativa Golfo Norte. Diario Oficial de la Federación. <http://bit.ly/3FfBaXc>. Accessed 10 March 2023.
- Doorembos, J. and Kassam, A.H. (1979). Yield response to water. No. 33. p. 193. Food and Agriculture Organization of the United Nations. <https://bit.ly/3yuJxL1>. Accessed 15 September 2021.

- Elsheikh, R., Mohamed Shariff, A.R.B., Amiri, F., Ahmad, N.B., Balasundram, S.K. and Soom, M.A.M. (2013). Agriculture Land Suitability Evaluator (ALSE): a decision and planning support tool for tropical and subtropical crops. *Computers and Electronics in Agriculture*, 93, 98–110. <https://doi.org/10.1016/j.compag.2013.02.003>.
- Flynn, K.C. (2019). Site suitability analysis for tef (*Eragrostis tef*) within the contiguous United States. *Computers and Electronics in Agriculture*, 159, 119–128. <https://doi.org/10.1016/j.compag.2019.02.016>.
- Hernández-Morales, L.M., García-Pérez, E., Cortés-Flores, J.I., Villegas-Monter, A. and Mora-Aguilera, J.A. (2021). Integral fertilization in Maars orange trees under production with Citrus Tristeza Virus (CTV) and HuangLongBing symptoms. *Revista Fitotecnia Mexicana*, 44(1), 59–66. <https://bit.ly/3lh3xgX>.
- Herrmann, S.M., Anyamba, A.S. and Tucker, C.J. (2005). Recent trends in vegetation dynamics in the African Sahel and their relationship to climate. *Global Environmental Change*, 15(4), 394–404. <https://doi.org/10.1016/j.gloenvcha.2005.08.004>.
- Holben, B.N. (1986). Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7(11), 1417–1434. <https://doi.org/10.1080/01431168608948945>.
- INEGI (2007a). Conjunto de datos vectorial edafológico, Serie II, Escala 1:250000, Continuo Nacional San Luis Potosí. <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=702825235673>. Accessed 25 June 2022.
- INEGI (2007b). Conjunto de datos vectorial edafológico, Serie II, Escala 1:250000, Continuo Nacional Ciudad Mante. <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=702825235680>. Accessed 25 June 2022.
- INEGI (2007c). Conjunto de datos vectorial edafológico, Serie II, Escala 1:250000, Continuo Nacional Ciudad Valles. <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=702825235710>. Accessed 25 June 2022.
- INEGI (2007d). Conjunto de datos vectorial edafológico, Serie II, Escala 1:250000, Continuo Nacional Guanajuato. <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=702825235703>. Accessed 25 June 2022.
- INEGI (2012). Continuo de Elevaciones Mexicano (CEM) version 3.0. Instituto Nacional de Estadística y Geografía (INEGI). <https://www.inegi.org.mx/app/geo2/elevacionesmex/>. Accessed 11 October 2021.

- INEGI (2013). Conjunto de datos de perfiles de suelos. Escala 1:250 000. Serie II (Continuo Nacional). <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=702825266707>. Accessed 25 June 2022.
- INEGI (2018). Mapas Topográficos. Escala 1:50 000. Serie III. San Luis Potosí. Instituto Nacional de Estadística y Geografía (INEGI). <https://bit.ly/3JiGkTU>. Accessed 15 April 2019.
- Jayathilaka, P.M.S., Soni, P., Perret, S.R., Jayasuriya, H.P.W. and Salokhe, V.M. (2012). Spatial assessment of climate change effects on crop suitability for major plantation crops in Sri Lanka. *Regional Environmental Change*, 12(1), 55–68. <https://doi.org/10.1007/s10113-011-0235-8>.
- Jolliffe, I.T. (2002). Principal component analysis. 2nd Ed. New York. Springer.
- Jurišić, M., Radočaj, D., Šiljeg, A., Antonić, O. and Živić, T. (2021). Current status and perspective of remote sensing application in crop management. *Journal of Central European Agriculture*, 22(1), 156–166. <https://doi.org/10.5513/JCEA01/22.1.3042>.
- Lanorte, A., Manzi, T., Nolè, G., and Lasaponara, R. (2015). On the use of the Principal Component Analysis (PCA) for evaluating vegetation anomalies from LANDSAT-TM NDVI temporal series in the Basilicata Region (Italy). In O. Gervasi, B. Murgante, S.
- Misra, M. L., Gavrilova, A. M. A. C., Rocha, C. Torre, *et al.* (Eds.), Computational Science and Its Applications -- ICCSA 2015 (Vol. 9158, pp. 204–216). Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-319-21410-8\\_16](https://doi.org/10.1007/978-3-319-21410-8_16).
- Lasaponara, R. (2006). On the use of principal component analysis (PCA) for evaluating interannual vegetation anomalies from SPOT/VEGETATION NDVI temporal series. *Ecological Modelling*, 194(4), 429–434. <https://doi.org/10.1016/j.ecolmodel.2005.10.035>.
- Layomi-Jayasinghe, J., Kumar, L. and Sandamali, J. (2019). Assessment of potential land suitability for tea (*Camellia sinensis* (L.) O. Kuntze) in Sri Lanka using a GIS-based multi-criteria approach. *Agriculture*, 9(7), 148. <https://doi.org/10.3390/agriculture9070148>.
- Li, B., Zhang, F., Zhang, L.W., Huang, J.F., Jin, Z.F. and Gupta, D.K. (2012). Comprehensive suitability evaluation of tea crops using GIS and a modified land ecological suitability evaluation model. *Pedosphere*, 22(1), 122–130. [https://doi.org/10.1016/S1002-0160\(11\)60198-7](https://doi.org/10.1016/S1002-0160(11)60198-7).

- Li, X., and Yeh, A.G.O. (2002). Urban simulation using principal components analysis and cellular automata for land-use planning. *Photogrammetric Engineering & Remote Sensing*, 68(4), 341–351.
- López-Blanco, J., Pérez-Damián, J.L., Conde-Álvarez, A.C., Gómez-Díaz, J.D. and Monterroso-Rivas, A.I. (2018). Land suitability levels for rainfed maize under current conditions and climate change projections in Mexico. *Outlook on Agriculture*, 47(3), 181–191. <https://doi.org/10.1177/0030727018794973>.
- Majsztrik, J.C., Behe, B., Hall, C.R., Ingram, D.L., Lamm, A.J., Warner, L.A. and White, S.A. (2019). Social and economic aspects of water use in specialty crop production in the USA: a review. *Water*, 11(11), 2337. <https://doi.org/10.3390/w11112337>.
- Malczewski, J. (2004). GIS-based land-use suitability analysis: a critical overview. *Progress in Planning*, 62(1), 3–65. <https://doi.org/10.1016/j.progress.2003.09.002>.
- Millward, A.A., Piwowar, J.M. and Howarth, P.J. (2006). Time-series analysis of medium-resolution, multisensor satellite data for identifying landscape change. *Photogrammetric Engineering & Remote Sensing*, 72(6), 653–663. <https://doi.org/10.14358/PERS.72.6.653>.
- Miranda-Aragón, L., Treviño-Garza, E.J., Jiménez-Pérez, J., Aguirre-Calderón, O.A., González-Tagle, M.A., Pompa-García, M. and Aguirre-Salado, C.A. (2012). NDVI-rainfall relationship using hyper-temporal satellite data in a portion of North Central Mexico (2000-2010). *African Journal of Agricultural Research*, 7(6). <https://doi.org/10.5897/AJAR11.1674>.
- Mohan-Babu, M.Y., Subramanyam, M.V. and Giri-Prasad, M.N. (2012). PCA based image denoising. *Signal & Image Processing: An International Journal*, 3(2), 236–244. <https://doi.org/10.5121/sipij.2012.3218>.
- Mokarram, M. and Mirsoleimani, A. (2018). Using Fuzzy-AHP and order weight average (OWA) methods for land suitability determination for citrus cultivation in ArcGIS (Case study: Fars province, Iran). *Physica A: Statistical Mechanics and its Applications*, 508, 506–518. <https://doi.org/10.1016/j.physa.2018.05.062>.
- Molina, E. (2000). Nutrición y fertilización de la naranja. *Informaciones Agronómicas*. No. 40. p. 8. San Carlos, Costa Rica: International Plant Nutrition Institute (IPNI). <https://bit.ly/3JymvZM>.
- New, M., Lister, D., Hulme, M. and Makin, I. (2002). A high-resolution data set of surface climate over global land areas. *Climate Research*, 21, 1–25. <https://doi.org/10.3354/cr021001>.

- Orhan, O. (2021). Land suitability determination for citrus cultivation using a GIS-based multi-criteria analysis in Mersin, Turkey. *Computers and Electronics in Agriculture*, 190, 106433. <https://doi.org/10.1016/j.compag.2021.106433>.
- Pilevar, A.R., Matinfar, H.R., Sohrabi, A. and Sarmadian, F. (2020). Integrated fuzzy, AHP and GIS techniques for land suitability assessment in semi-arid regions for wheat and maize farming. *Ecological Indicators*, 110, 105887. <https://doi.org/10.1016/j.ecolind.2019.105887>.
- Rahman, R. and Saha, S.K. (2008). Remote sensing, spatial multi criteria evaluation (SMCE) and analytical hierarchy process (AHP) in optimal cropping pattern planning for a flood prone area. *Journal of Spatial Science*, 53(2), 161–177. <https://doi.org/10.1080/14498596.2008.9635156>.
- Rosegrant, M.W., Ringler, C. and Zhu, T. (2009). Water for agriculture: maintaining food security under growing scarcity. *Annual Review of Environment and Resources*, 34(1), 205–222. <https://doi.org/10.1146/annurev.environ.030308.090351>.
- Rouse, R.WJr., Haas, R.H., Schell, J.A. and Deering, D.W. (1974). Monitoring vegetation systems in the great plains with ERTS. Vol. 1. pp. 309–317. Presented at the Third Earth Resources Technology Satellite-1 Symposium. Volume 1: Technical Presentations, Section A, NASA. Goddard Space Flight Center. <https://bit.ly/3nuMSHJ>. Accessed 10 May 2016.
- Ruiz-Corral, J.A., Medina-García, G., González-Acuña, I.J., Flores-López, H.E., Ramírez-Ojeda, G., Ortiz-Trejo, C., Byerly-Murphy, K.F. y Martínez-Parra, R.A. (2013). Requerimientos agroecológicos de cultivos. Segunda Edición. Libro Técnico Núm. 3. INIFAP. *Instituto Nacional de Investigaciones Forestales Agrícolas y Pecuarias-CIRPAC-Campo Experimental Centro Altos de Jalisco*. Tapatitlán de Morelos, Jalisco, México. 564 p.
- Saaty, T.L. (2004). Decision making — the Analytic Hierarchy and Network Processes (AHP/ANP). *Journal of Systems Science and Systems Engineering*, 13(1), 1–35. <https://doi.org/10.1007/s11518-006-0151-5>.
- 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>. Accessed 6 March 2023.
- Sannidi, S., Bindu, G.S.M., Neelima, T.L. and Umadevi, M. (2022). Soil quality mapping in the groundnut belt of erstwhile Mahabubnagar District, Telangana, India using GIS. *Current Science*, 122(5), 600. <https://doi.org/10.18520/cs/v122/i5/600-608>.
- Syedmohammadi, J., Sarmadian, F., Jafarzadeh, A.A. and McDowell, R.W. (2019). Development of a model using matter element, AHP and GIS techniques to assess

- the suitability of land for agriculture. *Geoderma*, 352, 80–95. <https://doi.org/10.1016/j.geoderma.2019.05.046>.
- Shafieezadeh, M., Moradi, H. and Fakheran, S. (2018). Evaluating and modeling the spatiotemporal pattern of regional-scale salinized land expansion in highly sensitive shoreline landscape of southeastern Iran. *Journal of Arid Land*, 10(6), 946–958. <https://doi.org/10.1007/s40333-018-0104-0>.
- Shaloo, B.H., Jain, R. and Singh, R.P. (2022). Cropland suitability assessment using multi criteria evaluation techniques and geo-spatial technology: a review. *The Indian Journal of Agricultural Sciences*, 92(5), 554–562. <https://doi.org/10.56093/ijas.v92i5.124622>.
- Steduto, P. (Ed.). (2012). Crop yield response to water. Rome: Food and Agriculture Organization of the United Nations. <https://www.fao.org/3/i2800e/i2800e.pdf>. Accessed 15 April 2022.
- Svoboda, M.D. and Fuchs, B.A. (2016). Handbook of drought indicators and indices. Geneva: World Meteorological Organization. <https://bit.ly/3Fbxy8J>. Accessed 8 March 2023.
- Tashayo, B., Honarbakhsh, A., Akbari, M. and Eftekhari, M. (2020). Land suitability assessment for maize farming using a GIS-AHP method for a semi- arid region, Iran. *Journal of the Saudi Society of Agricultural Sciences*, 19(5), 332–338. <https://doi.org/10.1016/j.jssas.2020.03.003>.
- Tercan, E. and Dereli, M.A. (2020). Development of a land suitability model for citrus cultivation using GIS and multi-criteria assessment techniques in Antalya province of Turkey. *Ecological Indicators*, 117, 106549. <https://doi.org/10.1016/j.ecolind.2020.106549>.
- Tshabalala, T., Ncube, B., Moyo, H.P., Abdel-Rahman, E.M., Mutanga, O. and Ndhlala, A.R. (2020). Predicting the spatial suitability distribution of Moringa oleifera cultivation using analytical hierarchical process modelling. *South African Journal of Botany*, 129, 161–168. <https://doi.org/10.1016/j.sajb.2019.04.010>.
- USDA (2021). Citrus Annual. No. MX2021- 0001. p. 14. United States Department of Agriculture, Foreign Agricultural Service, Global Agricultural Information Network. <https://bit.ly/3JjgLTR>. Accessed 6 March 2023.
- USDA (2023). Citrus: World Markets and Trade (Global Market Analysis). p. 15. Washington, DC.: United States Department of Agriculture, Foreign Agricultural Service, World Agricultural Outlook Board/USDA. <https://apps.fas.usda.gov/psdonline/circulars/citrus.pdf>. Accessed 9 March 2023.
- van Vliet, J., Eitelberg, D.A. and Verburg, P.H. (2017) A global analysis of land take in cropland areas and production displacement from urbanization. *Global*

*Environmental Change*, 43, 107–115.  
<https://doi.org/10.1016/j.gloenvcha.2017.02.001>.

- Wu, W. and Xin, Q. (2023) Characterizing spring phenological changes of the land surface across the Conterminous United States from 2001 to 2021. *Remote Sensing*, 15(3), 737. <https://doi.org/10.3390/rs15030737>.
- Xiong, Q., Chen, W., Luo, S., He, L. and Li, H. (2022). Temporal and spatial variation of land surface temperature in recent 20 years and analysis of the effect of land use in Jiangxi Province, China. *Atmosphere*, 13(8), 1278. <https://doi.org/10.3390/atmos13081278>.
- Xu, T., Li, E., Samat, A., Li, Z., Liu, W. and Zhang, L. (2022). Estimating large-scale interannual dynamic impervious surface percentages based on regional divisions. *Remote Sensing*, 14(15), 3786. <https://doi.org/10.3390/rs14153786>.
- Xu, Y., Yang, Y., Chen, X. and Liu, Y. (2022). Bibliometric analysis of global NDVI research trends from 1985 to 2021. *Remote Sensing*, 14(16), 3967. <https://doi.org/10.3390/rs14163967>.
- Yáñez-Rodríguez, M.A. (2019). Caracterización del Acuífero Río verde, San Luis Potosí con el Método Magnetotelúrico. Tesis de Maestría en Geociencias Aplicadas. Instituto Potosino de Investigación Científica y Tecnológica, San Luis Potosí, México. Retrieved from <https://bit.ly/3J32DN6>.
- Zabihi, H., Ahmad, A., Vogeler, I., Said, M.N., Golmohammadi, M., Golein, B. and Nilashi, M. (2015). Land suitability procedure for sustainable citrus planning using the application of the analytical network process approach and GIS. *Computers and Electronics in Agriculture*, 117, 114–126. <https://doi.org/10.1016/j.compag.2015.07.014>.
- Zabihi, H., Vogeler, I., Amin, ZM. and 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>.
- Zang, Y., Chen, X., Chen, J., Tian, Y., Shi, Y., Cao, X. and Cui, X. (2020). Remote sensing index for mapping canola flowers using MODIS data. *Remote Sensing*, 12(23), 3912. <https://doi.org/10.3390/rs12233912>.
- Zolekar, R.B and Bhagat, V.S. (2015). Multi-criteria land suitability analysis for agriculture in hilly zone: remote sensing and GIS approach. *Computers and Electronics in Agriculture*, 118, 300–321. <https://doi.org/10.1016/j.compag.2015.09.016>.

## CAPÍTULO 6

### DISCUSIÓN Y CONSIDERACIONES FINALES

Este trabajo de investigación propone técnicas de agricultura de precisión para mejorar la producción de naranja en la región de Rioverde, México. Se abordaron cuatro capítulos, en el primero se realizó una revisión exhaustiva para comprender la situación actual de la naranja en el mundo, producción, plagas y enfermedades, demanda, comercio, entre otros. También se investigó algunas de las técnicas de agricultura de precisión más novedosas enfocadas en mejorar la producción de naranja. Después, se generaron 3 capítulos que desarrollan el uso de técnicas de agricultura de precisión en una huerta ubicada dentro de la zona citrícola de la región de Rioverde. Los principales objetivos fueron generar inventarios de árboles de naranja, delinear zonas de manejo a partir de características de calidad y producción, identificación temprana de árboles con problemas de salud y la delimitación de nuevas zonas para el establecimiento de cultivos de naranja dentro de la región de Rioverde. Entre las técnicas y herramientas empleadas destacan, el uso de imágenes de percepción remota de alta y de muy alta resolución espacial, el uso de vehículos aéreos no tripulados, algoritmos de aprendizaje automático, análisis de componentes principales, entre otros. Se utilizaron bases de datos climáticos, topográficos, de suelo, hidrológicos, información de rendimiento y calidad de la fruta. A continuación, se describe en detalle cada uno de los capítulos desarrollados en esta investigación.

#### Capítulo 2

En el capítulo 2 se planteó la delimitación de zonas de manejo agrícola, generadas a partir de la calidad de la fruta. La delimitación de las zonas de manejo se realiza con diferentes objetivos, mejorar el rendimiento de los cultivos (Gavioli *et al.*, 2019), la disminución de daños al medio ambiente (Breunig *et al.*, 2020), analizar la calidad de la fruta, el control de plagas (Méndez-Vázquez *et al.*, 2019), y con fines de riego (Ouazaa *et al.*, 2022). La motivación de realizar este capítulo se derivó del problema de bajo rendimiento al que se enfrentó la huerta en los últimos años, disminuyendo su producción



hasta un 70 % en 6 años. El enfoque de esta investigación persiguió el objetivo de generar mapas de calidad y producción, que exhiben espacialmente las condiciones de calidad y producción de las diferentes variables medidas en la huerta y finalmente se generó un mapa general de zonas de manejo, teniendo tres zonas de calidad, alta, media y baja. Las zonas de manejo permiten enfocar los esfuerzos en zonas específicas de la huerta para homogenizar la producción.

Para este trabajo se usó tecnología de imágenes multiespectrales (sensor MAPIR) el cual se instaló en un UAV y del sensor Landsat 7. Derivado de este producto se generó un valioso inventario para tener un panorama a nivel de árbol en la huerta, también se utilizó para generar los mapas de calidad y producción, con lo que posteriormente se generó el mapa general de zonas de manejo de la huerta. A partir de la información de los mapas y con apoyo del inventario se pudo estimar el rendimiento por zona. El índice de vegetación NDVI también fue calculado y se pudo confirmar que las zonas con los árboles más saludables dieron el rendimiento y calidad más alto. El índice NDVI fue calculado para las imágenes del sensor MAPIR y Landsat, donde se pudo observar que arrojaron resultados similares.

Los resultados muestran 3 zonas de diferentes calidades bien definidas y que coinciden con lo observado en campo. Donde, la zona más apta de la huerta tiene una gran diferencia respecto a la zona menos favorable, teniendo una diferencia de 86 kg de rendimiento promedio por árbol. De la misma manera, en términos de calidad de la vegetación la zona de manejo con las mejores condiciones mostró un NDVI promedio de 0.46, mientras que la zona con la vegetación menos saludable obtuvo un NDVI promedio de 0.41. La metodología planteada resulta prometedora para manejar de manera más eficaz las huertas de naranja, ya que se puede realizar un manejo a nivel de árbol lo que permite tomar decisiones de manera informada, y lo más importante es que resulta económico generar y aplicar las zonas de manejo.

### Capítulo 3

Uno de los factores que más influyó en la huerta de estudio es el deterioro de salud de los árboles, incluso muchos han llegado al punto de secarse completamente, otros se han

caído antes de secarse y otros más han sido arrancados por el productor debido a su precario estado. En este sentido, para el tercer capítulo se analizó el estado de salud a nivel de árbol en la huerta, para ello se generó un inventario con las imágenes obtenidas a partir de vuelos realizados con un vehículo aéreo no tripulado, y mediante un sistema de información geográfica se etiquetó a cada árbol con una clave, incluyendo los espacios que de momento se encontraban sin árbol durante los vuelos. Sobre el UAV se adaptó una cámara multiespectral para poder obtener más información de la copa de los árboles. En los recorridos en campo se evaluaron los árboles y se generó un diagnóstico con la ayuda del productor el cual sirvió para entrenar un modelo de clasificación supervisada. Con el modelo obtenido se corrieron cinco algoritmos de aprendizaje automático, con lo cual se buscó el algoritmo que mejor desempeño obtuvo para clasificar el estado de salud de los árboles.

La evaluación de árboles de naranja mediante algoritmos complejos de aprendizaje automático, se pueden identificar árboles potencialmente enfermos y que de manera visual es complicado identificarlos por parte del productor. Los UAV's, generan muchas ventajas como la realización de vuelos programados en cualquier etapa fenológica, además, los procesos de las imágenes y algoritmos se pueden automatizar para lograr una aplicación más sencilla y de esta manera el productor obtenga resultados palpables, por ejemplo, visualizarlos en un teléfono inteligente.

Los resultados muestran un deterioro importante de los árboles de naranja presentes en la huerta. Los algoritmos con un mejor desempeño (ML= 88.10 y SVM= 77.38) muestran que la mayoría de los árboles tienen algún grado de enfermedad o estrés. Este diagnóstico es importante para el productor ya que de esta manera conoce cuáles son los árboles que presentan mayor riesgo de dejar de ser productivos, incluso aquellos que están con mayor riesgo de secarse o caerse. Esta investigación solo aborda hasta la parte metodológica, una segunda parte de este trabajo es lograr la programación de la metodología para visualizar los resultados de una forma más dinámica. Una de las principales desventajas, es el dinamismo de las plagas y enfermedades, por lo cual, tener un diagnóstico acertado del estado de salud de la huerta, implica la realización de vuelos constantes. En resumen, se

utilizaron imágenes de muy alta resolución espacial, un sistema GPS, SIG y algoritmos de aprendizaje automático, para monitorear cada árbol de manera individual.

#### Capítulo 4

En el capítulo 4, se abordó la problemática de los factores que ocasionan la pérdida y abandono de huertas de naranja. En este sentido, se propuso una técnica integradora de factores ambientales, climáticos, topográficos y de suelo en un entorno SIG, y con base en la opinión de expertos, se delimitaron zonas potenciales para el establecimiento de nuevas huertas de naranja, de acuerdo a las características que más favorecen la zona de estudio. Para este capítulo se utilizaron diferentes recursos de AP, entre ellos, percepción remota, SIG, GPS y métodos estadísticos como el Análisis de Componentes Principales. La metodología utilizada fue el análisis multicriterio (MCDA).

Se utilizó la delimitación del acuífero administrativo de Rioverde para acotar la zona de estudio. Se trabajó con una robusta base de datos diarios de precipitación de los últimos 20 años en la zona, obtenidos a través de imágenes de resolución moderada MODIS. a pesar de ser una zona mayormente semiárida, los resultados indican que una importante área del 30 % del acuífero están dentro una aptitud modera y alta para el cultivo de naranjos.

La metodología planteada en este capítulo resalta la importancia de generar modelos de aptitud del suelo tomando en cuenta series de tiempo y la precipitación anual que es clave en el cultivo de naranja. La región de estudio es una zona mayormente semiárida, por lo tanto, el acceso al agua resulta fundamental para la instalación de nuevas huertas productoras. Basados en los resultados, una huerta que pretenda instalarse en zonas con dificultades para el acceso al agua, tiene grandes posibilidades de no lograrse. Las zonas más aptas se concentran en una región pequeña, en su mayoría dentro de los límites del acuífero granular, lo cual resulta lógico tomando en cuenta la gran sequía que se ha vivido en los últimos años en la región. En la actualidad, dentro de esta zona, es imposible la producción de naranja comercial mediante riego de temporal. El análisis de componentes principales brindó un panorama más preciso de las zonas más aptas para la producción de

naranja. Este estudio resulta de gran relevancia para lograr un mejor manejo del cultivo de naranja en la región de Rioverde.

Los resultados fueron favorables, de acuerdo a las metodologías planteadas, el productor y dueño de la huerta de estudio, ha manifestado que está dispuesto a llevar a cabo las recomendaciones que se puedan generar derivado de este trabajo, lo cual fortalece la aplicación de este tipo de investigaciones. No obstante, existe un número importante de productores que declara no estar dispuesto a utilizar técnicas de agricultura de precisión, muy probablemente por el desconocimiento de sus beneficios.

Para darnos una idea de la perspectiva que tienen los productores de naranja en esta región, se realizó una encuesta, la mayoría de los productores coincide en que la producción y la calidad de la fruta disminuyó drásticamente en la última década, no se sabe a bien la causa exacta de esta debacle, se presume una serie de factores que pudieron o están influyendo, como el uso excesivo de riego y productos químicos, la presencia de HLB y hongos que perjudican el suelo y la planta directamente. Por si fuera poco, el problema de las plagas y enfermedades, todo parece indicar que se aproxima un nuevo reto “la escasez del agua”. La producción agrícola de esta región depende en gran medida del riego de agua subterránea y de las aguas de un importante manantial conocido como “La Media Luna” (Charcas-Salazar *et al.* 2002). De acuerdo a la CONAGUA (2020), la disponibilidad de agua del acuífero granular de la zona se redujo 62% en 14 años. Esta situación ha generado abatimiento en el acuífero y los productores han visto disminuir el nivel de sus pozos. La variabilidad anual de las precipitaciones influye fuertemente en la disponibilidad de agua durante todo el año. Las precipitaciones que normalmente oscilaban entre los 375 y 604 mm anuales (Charcas-Salazar *et al.*, 2002) en la actualidad muestran otro comportamiento, de acuerdo a la información del Sistema Meteorológico Nacional (SMN) de la CONAGUA, en los últimos años oscilan entre los 300 y 400 mm anuales en la zona productora, generando varios problemas, entre los que destacan, 1) bajo rendimiento de producción y fruta de mala calidad, 2) problemas de salud en los árboles y 3) el abatimiento de fuentes para el riego en algunas huertas. Estos problemas han motivado el abandono de la actividad citrícola en la región por parte de algunos productores. De continuar esta tendencia, las áreas productoras de naranja podrían seguir

disminuyendo. De acuerdo a información (no publicada), del comité técnico de aguas subterráneas (COTAS) de Rioverde, la tecnificación del riego en esta zona comenzó en los años 2000, anteriormente se regaba de manera tradicional con el riego rodado a cielo abierto, se estima que una sola hectárea consumía 12,000 m<sup>3</sup>, la tecnificación ahorra más del 50% de lo que consumía el riego rodado. El mismo COTAS asegura que existe un 80% de huertas con tecnificación de riego en esta región, sin embargo, estos números no parecen ser suficientes antes la escasez que parece inevitable. Conocer el contexto de los problemas que existen en la región y la crisis hídrica que se avecina, exige que se busquen nuevas gestiones si se quiere mantener la zona citrícola, parece difícil que el manejo actual soporte una crisis del agua. Las técnicas propuestas en este trabajo, pueden ayudar a optimizar recursos, reducir impactos negativos en el medio ambiente, atacar problemas fitosanitarios a tiempo y elegir adecuadamente nuevas áreas para el establecimiento exitoso de huertas productoras. Está claro que existen muchas barreras para llevar a cabo la aplicación de la agricultura de precisión, sin embargo, la mejor manera de lograr su establecimiento es la difusión entre productores.

## LITERATURA CITADA

- Actualización de la disponibilidad de agua promedio anual en el acuífero de Rioverde (2415), estado de San Luis Potosí, (2020). Subdirección técnica general de manejo de aguas subterráneas. Ciudad de México: *Comisión Nacional del Agua* (CONAGUA).
- Breunig, F.M., Soares-Galvao, L., Dalagnol, R., Dauve, C.E., Parraga, A., Santi, A.L., Della-Flora, D.P. and Chen, S. (2020). Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. *International Journal of Applied Earth Observation and Geoinformation*, 85, 102004. <https://doi.org/10.1016/j.jag.2019.102004.9>.
- Charcas-Salazar, H., Olivares-Sáenz, E. and Aguirre-Rivera, J.A. (2002). Irrigation water in Rioverde region, San Luis Potosi, Mexico. *Ingeniería Hidráulica en México* 17(4), 37–56. <http://bit.ly/3l691ew>.
- CONAGUA. (2021). Resúmenes mensuales de temperatura y lluvias (en línea). Climatología. Disponible en: [smn.conagua.gob.mx/es/climatologia/temperaturas y lluvias/resumenes-mensuales-de-temperaturas-y-lluvias](http://smn.conagua.gob.mx/es/climatologia/temperaturas-y-lluvias/resumenes-mensuales-de-temperaturas-y-lluvias) [Consultado en junio 2021].
- Furtak, K. and Wolinska, A. (2023). The impact of extreme weather events as a consequence of climate change on the soil moisture and on the quality of the soil environment and agriculture – A review. *Catena*, 231, 107378.
- Gavioli, A., de Souza, E.G., Bazzi, C.L., Schenatto, K. and Betzek, N.M. (2019). Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. *Biosystems Engineering*, 181, 86–102. <https://doi.org/10.1016/j.biosystemseng.2019.02.01>.
- Méndez-Vázquez, L.J., Lira-Noriega, A., Lasa-Covarrubias, R. and Cerdeira-Estrada, S. (2019). Delineation of site-specific management zones for pest control purposes: Exploring precision agriculture and species distribution modeling approaches. *Computers and Electronics in Agriculture*, 167, 105101.
- Ouazaa, S., Jaramillo-Barrios, C.I., Chaali, N., Quevedo-Amaya, Y.M., Calderon-Carvajal, J.E. and Montenegro-Ramos, O. (2022). Towards site specific management zones delineation in rotational cropping system: Application of multivariate spatial clustering model based on soil properties. *Geoderma Regional*, 30, e00564. <https://doi.org/10.1016/j.geodrs.2022.e00564>.

## ANEXOS

### **Anexo 1**

Manuscrito publicado en *AgriEngineering* como: Díaz-Rivera, J.C., Aguirre-Salado, C.A., Miranda-Aragón, L. and Aguirre-Salado, A.I. 2024. Some Geospatial Insights on Orange Grove Site Selection in a Portion of the Northern Citrus Belt of Mexico. *AgriEngineering*, 6(1):259–284. <https://doi.org/10.3390/agriengineering6010016>