LICENCIA DE USO OTORGADA POR IRMA VIRIDIANA VALENZUELA RUIZ, de nacionalidad Mexicana mayor de edad, con domicilio ubicado en: Rio Papaloapan 1059, Los Pinos, en mi calidad de titular de los derechos patrimoniales y morales y autor de la tesis denominada **"OPTIMIZACIÓN DEL CULTIVO DE CHILE MORRÓN (CAPSICUM ANNUMM) MEDIANTE SU MONITOREO UTILIZANDO ÍNDICES ESPECTRALES"** en adelante **"LA OBRA"** quien para todos los fines del presente documento se denominará **"EL AUTOR Y/O EL TITULAR"**, a favor del Instituto Tecnológico de Culiacán del Tecnológico Nacional de México, la cual se regirá por las cláusulas siguientes:

PRIMERA –OBJETO: "EL AUTOR Y/O TITULAR", mediante el presente documento otorga al Instituto Tecnológico de Culiacán del Tecnológico Nacional de México, licencia de uso gratuita eindefinida respecto de **"LA OBRA"**, para almacenar, preservar, publicar, reproducir y/o divulgar la misma, con fines académicos, por cualquier medio en forma física y a través del repositorio institucional y del repositorionacional, éste último consultable en la página: (https://rinacional.tecnm.mx/).

SEGUNDA - TERRITORIO: La presente licencia se otorga, de manera no exclusiva, sin limitación geográfica o territorial alguna, de manera gratuita e indefinida.

TERCERA -ALCANCE: La presente licencia contempla la autorización para formato uso de "LA OBRA" en cualquier formato o soporte material y se extiende a la utilización, de manera enunciativa más no limitativa alos siguientes medios: óptico, magnético, electrónico, virtual (red), mensaje de datos o similar conocido por conocerse en medio óptico, magnético, electrónico, en red, mensajes de datos o similar, conocido o por conocerse.

CUARTA – EXCLUSIVIDAD: La presente licencia de aquí establecida no implica exclusividad en favor del Instituto Tecnológico de Culiacán; por lo tanto, **"EL AUTOR Y/O TITULAR"** conserva los derechos patrimoniales y morales de **"LA OBRA"**, objeto del presente documento.

QUINTA – CRÉDITOS: El Instituto Tecnológico de Culiacán y/o el Tecnológico Nacional de México reconoce que el "**AUTOR Y/O TITULAR**" es el único, primigenio y perpetuo titular de los derechos morales sobre "LA OBRA"; por lo tanto, siempre deberá otorgarle los créditos correspondientes por la autoría de la misma.

SEXTA – AUTORÍA: **"EL AUTOR Y/O TITULAR"** manifiesta ser el único titular de los derechos de autor que derivan de **"LA OBRA"** y declara que el material objeto del presente fue realizado por él, sin violentar o usurpar derechos de propiedad intelectual de terceros; por lo tanto, en caso de controversia sobre los mismos, se obliga a ser el único responsable.

Dado en la ciudad de Culiacán Rosales, Sinaloa, a los 11 días del mes de abril del 2025.

"EL AUTOR Y/O TITULAR"	"EL INSTITUTO TECNOLÓGICO DE CULIACÁN"
IRMA VIRIDIANA VALENZUELA RUIZ	FRANCISCA PIÑA ZAZUETA

TECNOLOGICO NACIONAL DE MÉXICO
Instituto Tecnológico de Culiacán

TITULACIÓN INTEGRAL

OPCIÓN:

TESIS PROFESIONAL

NOMBRE DEL PROYECTO:

"Optimización del cultivo de chile morrón (*Capsicum annumm)* mediante su monitoreo utilizando índices espectrales"

ALUMNO:
Irma Viridiana Valenzuela Ruiz

CARRERA:
Ingeniería Industrial

No. DE CONTROL:
20171451

Culiacán, Sinaloa 2025.

HOJA DE AUTORIZACIÓN

Educación
Secretaría de Educación Pública

TECNOLÓGICO NACIONAL DE MÉXICO

Instituto Tecnológico de Culiacán

DIVISION DE ESTUDIOS PROFESIONALES
ASUNTO: **Autorización de Impresión**

Culiacán, Sinaloa, 18/03/2025 17:00

C. IRMA VIRIDIANA VALENZUELA RUIZ
PASANTE(S) DE LA CARRERA DE INGENIERÍA INDUSTRIAL
P R E S E N T E.

De acuerdo con fallo emitido por la Comisión Revisora Integrada por:

		Cédula Profesional
Presidente:	Doctor en Ciencia y Tecnología con Especialidad en Ingeniería Ambiental	
	Jesús Gabriel Rangel Peraza	8327423
Secretario:	Maestría en Ciencia y Tecnología con especialidad en Ingeniería Ambiental	
	Edith Padilla Gasca	10320464
Vocal:	Licenciatura en Ingeniería Ambiental	
	Osiris Chávez Martínez	11928597

Y considerando que reúne los requisitos establecidos en la Opción: **TITULACIÓN INTEGRAL: TESIS PROFESIONAL "OPTIMIZACIÓN DEL CULTIVO DE CHILE MORRÓN (CAPSICUM ANNUM) MEDIANTE SU MONITOREO UTILIZANDO INDICES ESPECTRALES"**, damos a usted nuestra autorización para que proceda a imprimir su trabajo profesional.

Sin otro particular, quedo de usted.

A T E N T A M E N T E
Excelencia en Educación Tecnológica®

CONCEPCION MENDOZA R.

LIC. CONCEPCIÓN MENDOZA ROSALES
JEFA DE LA DIVISIÓN DE ESTUDIOS PROFESIONALES

EDUCACIÓN
INSTITUTO TECNOLÓGICO DE CULIACÁN
DEPARTAMENTO DE DIVISION DE ESTUDIOS PROFESIONALES

2025 Año de La Mujer Indígena

Juan de Dios Bátiz 310 Pte. Col. Guadalupe C.P. 80220
Culiacán, Sinaloa. Tel. 667-454-0100
tecnm.mx www.culiacan.tecnm.mx

DEDICATORIA

A mi madre

Por enseñarme a ser fuerte y valiente ante las adversidades, te agradezco por cada sacrificio y por la confianza que siempre ha depositado en mí. Madre, cada éxito mío lleva tu huella, porque me has dado más de lo que jamás podría agradecer. Te dedico este trabajo con todo mi amor y gratitud.

A mi padre

La figura de un padre es un regalo invaluable. Gracias por ser ese regalo en mi vida, por tu confianza, tu paciencia y por siempre estar dispuesto a darme lo mejor de ti.

A mis hermanos

Por su amor, apoyo y compañía incondicional. Gracias por ser mis compañeros de vida, mis amigos más cercanos y los que siempre me han impulsado a ser mejor. Pero sobre todo gracias por siempre creer en mí. Este logro también es de ustedes, los amo con todo mi corazón.

A doña María

Mi querida abuela, gracias por siempre llenarme de bendiciones, por tu amor incondicional y tus buenos consejos. Este logro es para ti que me viste crecer y convertirme en la gran mujer que soy, gracias por ser una parte fundamental en mi vida.

A mis amigas

A Sarahi, Juanita y Kitzia, quienes me han enseñado lo que significa la verdadera amistad. Gracias por ser mis cómplices, mis consejeras y mi fuente de alegría.

AGRADECIMIENTO

A la institución

Agradezco a la institución y a mis profesores por brindarme su conocimiento y guía a lo largo de mi estancia en el Instituto Tecnológico de Culiacán.

A mis tutores

Expreso mi agradecimiento al Dr. Jesús Gabriel Rangel Peraza y a la Dr. Edith Padilla Gasca por su invaluable dedicación y orientación, cuyas enseñanzas, experiencias y compromisos fueron fundamentales para enriquecer mi trabajo y alcanzar los objetivos. Asi mismo agradezco a M.C.I Osiris Chávez por su valiosa contribución y asesoramiento durante el desarrollo del proyecto.

OPTIMIZACIÓN DEL CULTIVO DE CHILE MORRÓN (*CAPSICUM ANNUMM*) MEDIANTE SU MONITOREO UTILIZANDO ÍNDICES ESPECTRALES

RESUMEN

En este proyecto se realizó un estudio de diversos índices de vegetación (RVI, GVI, NDVI, IPVI, GNDVI, OSAVI, WDRVI y TNDVI) para estudiar el comportamiento de un cultivo de chile morrón, haciendo uso de imágenes satelitales y un VANT (Vehículo Aéreo No Tripulado) con una cámara multiespectral que incluye las bandas RGN (rojo, verde e infrarrojo cercano). Las imágenes capturadas son de una parcela que cuenta con dos especies de chile morrón (chile Percheron y chile Hassium) y que está dividida en cuatro polígonos (M1, M2, M3 y M4); M1 y M3 corresponden a cultivos con insumos orgánicos, mientras que M2 y M4 son los cultivos testigo.

Para el monitoreo se hizo uso de los sensores Sentinel-2, PlanetScope y VANT. Para la adquisición de las imágenes satelitales se tomaron como referencia los 8 vuelos del dron, se trabajó de manera separada cada sensor para realizar aplicar a cada uno los índices antes mencionados. Además, para cada polígono de cada índice se extrajo el promedio y la desviación estándar para posteriormente realizar una prueba de diferencia de medias y un análisis de varianza (ANOVA).

Los resultados de la tabla ANOVA para los índices de vegetación analizados mostraron diferencia estadística significativa para el vuelo y también para el tipo de sensor utilizados. Pero la especie de chile no presenta evidencia estadística significativa en la mayoría de los índices, únicamente es significativo en el índice RVI.

En definitiva, los resultados derivados de estos análisis son fundamentales para optimizar el cultivo de chile, ya que facilitan la adopción de prácticas agrícolas más eficientes y sostenibles, contribuyendo tanto al incremento de la productividad como a la mejora de la rentabilidad y la competitividad en el mercado.

Palabras clave: índices de vegetación, agricultura de precisión, teledetección.

CONTENIDO

1 INTRODUCCIÓN 1

1.1 Planteamiento del problema 4

1.2 Descripción de la empresa u organización y del puesto o área del trabajo del estudiante 6

1.3 Objetivo general 7

1.4 Objetivos específicos 7

1.5 Justificación 8

1.6 Alcance 10

2 FUNDAMENTO TEÓRICO 11

2.1 Marco conceptual 11

2.1.1 Agricultura 11

2.1.2 Agricultura de precisión 11

2.1.3 Espectro electromagnético 12

2.1.4 Imagen digital 14

2.1.5 Imagen multiespectral 14

2.1.6 Ortomosaicos 14

2.1.7 Sistemas de información geográfica 15

2.1.8 Índices de vegetación 15

2.1.9 Diseño de experimentos 19

2.1.10 Matriz de diseño 19

2.1.11 Análisis de varianza 19

2.1.12 Sensores remotos 20

2.2 Marco teórico 22
2.2.1 Teledetección 22
2.3 Estado del arte 24
3 DESCRIPCIÓN DE ACTIVIDADES 26
3.1 Delimitación del área de estudio 26
3.2 Tipo y condición del cultivo 26
3.3 Imágenes obtenidas con el dron 28
3.4 Acceso de las plataformas satelitales 30
3.5 Preparación de imágenes satelitales 30
3.6 Clasificación de los pixeles con los ortomosaicos de los vuelos del dron 32
3.7 Análisis estadístico 32
4 RESULTADOS 37
4.1 Adquisición de imágenes mediante dron 37
4.2 Generación de ortomosaicos 38
4.3 Cálculo de los índices espectrales mediante las imágenes del dron 39
4.4 Imágenes satelitales 42
4.5 Obtención de índices espectrales para imágenes satelitales 43
4.6 Análisis estadístico 45
4.6.1 Prueba para diferencia entre medias de muestras grandes 45
4.6.2 Análisis de varianza (ANOVA) 46
5 CONCLUSIONES 54
6 COMPETENCIAS DESARROLLADAS 55
7 FUENTES DE INFORMACIÓN 56

8 ANEXOS 66

8.1 Ortomosaicos para los V2, V3, V4, V5, V7 Y V8 del dron respectivamente. 66

8.2 Ejemplo del código en R para el vuelo 7. 67

8.3 Tablas de prueba de medias entre sensores para el V2 con polígono M2, M3, M4. 79

8.4 Tablas ANOVA para los índices RVI, GVI, IPVI, GNDVI, OSAVI, WDRVI y TNDVI respectivamente. 81

8.5 Gráfico de comportamiento individual para cada sensor en cada vuelo de los índices GVI, NDVI, IPVI, WDRVI y TNDVI respectivamente. 84

8.6 Gráficos de los resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para los índices NDVI, IPVI, GNDVI, WDRVI, TNDVI. 86

8.7 Carta de no inconveniente 90

ÍNDICE DE FIGURAS

Figura 2.1. Longitud de onda, frecuencia y velocidad de propagación. Fuente: (ESERO Spain, s.f.) 13

Figura 2.2. Espectro electromagnético. Fuente: (García & Lárez Velásquez, 2020) 13

Figura 3.1. Localización del área de estudio. 26

Figura 3.2. Cultivo de chile morrón (*Capsicum annumm*). 27

Figura 3.3. División de la parcela donde M1, M3 son cultivos orgánicos y M2, M4 corresponden a los cultivos testigo. 28

Figura 3.4. Phantom 4 Pro. Fuente: Fotografía propia 29

Figura 3.5. Distribución normal de la diferencia entre dos medias a un nivel de significancia de 0.05. Fuente: (Levin & Rubin, 2004) 33

Figura 3.6. Región de rechazo y de aceptación para hipótesis. Fuente: (Gutiérrez Pulido & de la Vara Salazar, 2008) 34

Figura 4.1. Ortomosaico del vuelo 6 con fecha 28/01/24. 38

Figura 4.2. Mascara binaria para el vuelo 1 de la fecha 05/11/23 40

Figura 4.3. Descarga de imágenes en Planet Explorer. 42

Figura 4.4. Plataforma Copernicus para descarga de imágenes de Sentinel-2. 43

Figura 4.5. a) área de estudio para el V1 de PlanetScope b) área de estudio para la imagen del V1 de Sentinel-2. 43

Figura 4.6. Índice de vegetación NDVI para el vuelo 6 de PlanetScope. 45

Figura 4.7. Gráfico del comportamiento individual para cada sensor en cada vuelo del RVI. 48

Figura 4.8. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice RVI. 49

Figura 4.9. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice GVI 50

Figura 4.10. Gráfico del comportamiento individual para cada sensor en cada vuelo del GNDVI. 51

Figura 4.11. Gráfico del comportamiento individual para cada sensor en cada vuelo del OSAVI 52

Figura 4.12. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice OSAVI. 53

ÍNDICE DE TABLAS

Tabla 3.1. Características de la cámara MAPIR 29

Tabla 3.2. Fechas de los vuelos con VANT y fechas de las imágenes descargadas de Copernicus y Planet 30

Tabla 3.3. Índices de vegetación con su respectiva ecuación 31

Tabla 3.4 Fórmulas para ANOVA multifactorial 35

Tabla 3.5. Comparación de medias 35

Tabla 4.1. Parámetros del vuelo con la cámara RGN. 37

Tabla 4.2. Configuración de los parámetros de la cámara de los vuelos efectuados 37

Tabla 4.3. Bitácora de las imágenes obtenidas con la cámara multiespectral (RGN). 39

Tabla 4.4. Medias y desviaciones estándar para el vuelo 2 con fecha 05/11/23. 41

Tabla 4.5. Media y desviación estándar para vuelo 7 de Sentinel-2. 44

Tabla 4.6. Media y desviación estándar para vuelo 6 de PlanetScope. 44

Tabla 4.7. Prueba de medias entre los sensores para el V2 con el polígono M1. 46

Tabla 4.8. Análisis ANOVA para el índice NDVI. 47

Tabla 4.9. Resultado de los Valores P de los IV analizados 47

1 INTRODUCCIÓN

La agricultura es la principal fuente de producción de alimentos, se encarga de proporcionar insumos esenciales y mano de obra al sector agroindustrial y al de servicios. Además, es una actividad que demanda una gran cantidad de recursos, entre ellos: fertilizantes, herbicidas, plaguicidas, maquinaria, entre otros. En el aspecto social, esta actividad promueve el vínculo de las personas con sus tierras, proporciona sustento a las familias y contribuye a la conservación de los recursos naturales en las comunidades productoras (Secretaría de Agricultura y Desarrollo Rural, 2023).

El Servicio de Información Agroalimentaria y Pesquera (Servicio de Información Agroalimentaria y Pesquera, 2016) señala que México ocupó el noveno lugar a nivel mundial en la producción de hortalizas, alcanzando un total de 14.1 millones de toneladas de diversas especies cultivadas en todo el país. Esta cantidad representó un incremento del 6% en comparación con el año anterior. La producción de hortalizas es una de las actividades agropecuarias más rentables en México, ya que el área agrícola total del país abarca 19,853,518.74 hectáreas (ha), de las cuales las hortalizas representan el 2.7% del total nacional y contribuyen con el 16% al valor total de la producción durante el período de 2007 a 2010. Estos valores reflejan la importancia que tienen las hortalizas en la economía nacional (Ayala Garay, Schwentesius Rindermann, & Carrera Chávez, 2012).

De acuerdo con la información proporcionada por CODESIN (CODESIN, 2023) en el año 2022, en Sinaloa la producción agrícola tuvo un valor en el mercado de 70 mil 195 millones de pesos (mdp). Por tipo de producto, el valor de producción de los granos fue de 40,795 mdp; hortalizas 18,034 mdp; leguminosas 6,128 mdp; caña de azúcar 389 mdp; frutas 2,338 mdp; y otros cultivos 2,510 mdp.

Los cultivos de granos y hortalizas enfrentan una serie de problemas que incluyen diferentes enfermedades, plagas y malezas, las cuales afectan desde la semilla hasta la planta y los frutos, estos problemas han podido ser mitigados mediante la aplicación de plaguicidas. En Sinaloa el uso de plaguicidas químicos sustenta la actividad agrícola, misma que ha generado problemas de contaminación en el suelo, agua, biota y sedimentos, esto derivado de las descargas de estas

sustancias tóxicas a los sistemas lagunares, vía drenes, riego y lluvia, por lo que esta situación constituye un factor de riesgo de contaminación para los ecosistemas terrestres y marinos (García Gutiérrez & Rodríguez Meza, 2012).

Una de las tecnologías que ha experimentado un notable crecimiento en los últimos tiempos es la percepción remota, la cual ha permitido nuevas aplicaciones en el análisis de imágenes satelitales. Al procesar estas imágenes, se pueden obtener datos precisos sobre diversos fenómenos en la superficie de la tierra, incluyendo la distribución de cultivos, los daños ocasionados por plagas y enfermedades, o sobre algún evento climatológico. Esta tecnología ha captado considerable interés entre los agricultores, ya que las imágenes satelitales les brindan la capacidad de evaluar rápidamente el estado de sus cultivos y determinar qué áreas requieren atención adicional (Aguilar Rivera, 2015).

En los últimos años, la cuarta revolución industrial tiene una manifestación muy importante en el sector agrícola. La agricultura de precisión (AP), optimización del agua y fertilizantes, la utilización de drones, incremento en la vida de anaquel y desde luego el uso de la biotecnología verde, ha propiciado mayores niveles de producción y de calidad en las cosechas.

Una de las técnicas que más se ha venido utilizando en la agricultura de Sinaloa es el riego de precisión. Para llevar a cabo de manera eficiente dicho riego, los agricultores deben monitorear sus parcelas con el fin de obtener información sobre aspectos relacionados con el clima, el porcentaje de humedad que tiene el suelo, el tipo de fertilizante que se debe realizar, la cantidad de agua necesaria para mantener la planta hidratada, entre otros. Cuando se tienen disponibles todos los datos, mediante el uso de paquetes computacionales, se procede a efectuar modelos de simulación y predicción que sirvan para llevar a cabo una representación de la información obtenida y, con base en ello, tomar las decisiones más acordes con las circunstancias (Bajo, Ríos Flores, & Zazueta, 2021).

La AP se distingue por la gestión (análisis y control) de la variabilidad espacial y temporal del terreno y de los cultivos. Ayudando a suministrar distintas cantidades de insumos tomando en cuenta la variación en los componentes del suelo (como textura, acidez, humedad, topografía o relieve), el desarrollo vegetal y las condiciones entre temporadas de siembra (Ocampo & Santa Catarina, 2018).

En este proyecto se propone implementar un sistema de monitoreo para el cultivo de chile morrón (*Capsicum annumm*) en el estado de Sinaloa, mediante el uso de técnicas de AP, debido a que la detección temprana de problemáticas relacionadas con el estrés de las plantas es fundamental para optimizar el rendimiento y la calidad del cultivo. Al integrar tecnologías avanzadas en la gestión agrícola, se busca no solo mejorar la salud de las plantas, sino también facilitar una toma de decisiones más informada y efectiva.

1.1 Planteamiento del problema

El pimiento o chile morrón es utilizado en México como especia o condimento, el cual posee un alto valor nutritivo y bajo contenido en grasas, así como gran cantidad de agua, rico en vitaminas, minerales, carbohidratos y fibra (Aguirre Hernández & Muños Ocotero, 2015). El estado de Sinaloa es el principal productor de chile morrón a cielo abierto, La (Secretaría de Agricultura y Desarrollo Rural;, 2022) resaltó que al año Sinaloa aporta alrededor de 166 mil toneladas de este producto.

Un gran reto en la producción de chile morrón es la ausencia de métodos de monitoreo que sean efectivos para identificar de manera temprana situaciones como el estrés por falta de agua, carencias nutricionales, o la aparición de plagas. Los métodos de monitoreo convencionales frecuentemente resultan costosos, consumen mucho tiempo y no siempre ofrecen la precisión necesaria. Esto dificulta que los productores puedan actuar a tiempo para solucionar los problemas, lo que a menudo resulta en una disminución tanto en la calidad como en el rendimiento del cultivo.

La AP es una estrategia de gestión que recoge, procesa y analiza datos temporales, espaciales e individuales y los combina con otras informaciones para respaldar las decisiones de manejo de acuerdo con la variabilidad estimada (Ríos Hernández, La Agricultura de Precisión. Una necesidad actuales, 2021). De este modo, se logra optimizar la eficiencia en el uso de recursos, así como mejorar la productividad, calidad, rentabilidad y sostenibilidad de la producción agrícola. Considerar la variabilidad en la gestión de los cultivos significa basar el razonamiento en las áreas dentro de la parcela que presentan características distintas. En este sentido, las nuevas tecnologías utilizadas por la AP pretenden sustituir esta práctica “visual” por sistemas como el GPS (*Global Positioning System*), la utilización de imágenes de satélites, el empleo de captadores, etc. cuyo objetivo es el de mejorar y facilitar la determinación y conocimiento de estas variabilidades presentes en el interior de las parcelas (Gil, 2010) .

Adicionalmente, los índices de vegetación (IV) representan un extracto de la información satelital relacionada con la vegetación, minimizando la influencia de otros factores como el suelo, las condiciones de iluminación, la vegetación seca y la atmósfera. Esto facilita una evaluación sistemática de la cantidad, calidad y desarrollo de la vegetación en un cultivo. (Balbontín, y otros, 2016).

Así, las decisiones acerca de cómo abordar las distintas operaciones agrícolas se toman conociendo la localización de las zonas en las que hay o no infestaciones de malezas, en las que existe o no necesidad de aumentar la dosis de determinado fertilizante, o en las que se requiere ajustar otras prácticas de manejo en función de las condiciones topográficas a nivel intra-lote, entre muchos otros aspectos involucrados en el manejo de los cultivos (Di Leon, 2015).

1.2 Descripción de la empresa u organización y del puesto o área del trabajo del estudiante

El Tecnológico Nacional de México – Instituto Tecnológico de Culiacán es una institución pública de nivel superior. Desde el año 1968 se dedica a la formación de profesionistas en diversas áreas de la ingeniería y la tecnología, cuenta con 11 programas educativos a nivel licenciatura y 4 programas de posgrado.

Cuenta con un certificado del Sistema Integrado de Gestión, el cual avala que cumple con las normas ISO 9001:2015, ISO 14001:2015, ISO 45001:2018, e ISO 50001:2018. Esta certificación abarca el proceso educativo desde la inscripción hasta la entrega del título y cédula profesional de licenciatura, incluyendo aspectos académicos y administrativos. Además, permite identificar cuestiones ambientales en laboratorios y talleres, así como en actividades de mantenimiento y servicios generales, priorizando la seguridad, la salud laboral y la mejora del rendimiento.

Además de las oficinas y aulas, el tecnológico cuenta con varios laboratorios especializados que apoyan la formación práctica de sus estudiantes en diversas áreas de la ingeniería. Para el desarrollo de este proyecto se hará uso del Laboratorio de Geomática y Teledetección, donde su servidora Viridiana Valenzuela llevará a cabo los estudios pertinentes con el apoyo del Dr. Gabriel Rangel y M.C.I Osiris Chávez.

1.3 Objetivo general

Calcular los valores de diversos índices de vegetación para identificar el comportamiento de un cultivo de chile morrón (*Capsicum annumm*) a cielo abierto y compararlos estadísticamente con los valores obtenidos a partir de imágenes satelitales.

1.4 Objetivos específicos

- Adquirir los ortomosaicos de los vuelos realizados con el dron.
- Analizar los índices espectrales de los datos capturados por el dron.
- Descargar las imágenes del satélite por medio de dos constelaciones.
- Obtener los índices de las imágenes de satélite.
- Comparar estadísticamente los valores obtenidos de los índices espectrales del dron contra los índices del satélite.

1.5 Justificación

Sinaloa es conocido como el “Granero de México”, por su destacada producción agrícola, especialmente de granos y hortalizas, tanto para el consumo nacional como para la exportación. Gracias a que el estado cuenta con un clima tropical, permite el cultivo de 1,245,638 hectáreas, de las cuales aproximadamente el 40% son de riego, el 50% de temporal y el 10% de riego y temporal. De acuerdo con (CODESIN, 2024) en el año 2023 Sinaloa cultivó 1 millón 016 mil 995 hectáreas, las cuales produjeron 12 millones 388 mil 925 toneladas de alimentos con un valor de producción de 80 mil 187 millones de pesos. Con base en la importancia mencionada anteriormente sobre los cultivos agrícolas es fundamental la detección de cualquier anomalía (estrés, enfermedades, plagas, entre otras) temprana en la planta. Por lo cual, el presente estudio tiene por objetivo utilizar un sistema de monitoreo de cultivos mediante índices espectrales para mejorar la productividad y los rendimientos en cultivos agrícolas en Sinaloa.

La implementación de sistemas de monitoreo mediante índices espectrales no solo mejora la detección temprana de problemas en los cultivos, sino que también promueve prácticas agrícolas más sostenibles. Esto puede resultar en un uso más eficiente de los recursos, como el agua y los insumos.

La AP ofrece la posibilidad de recolectar, analizar y utilizar información específica de las explotaciones, convirtiendo datos e información en conocimiento y rentabilidad. Estos sistemas no sólo posibilitan una gestión agronómica más eficaz, sino que además permiten aumentar la precisión de las labores y la eficiencia de los equipos (García & Flego, 2008). Sus resultados se concretan en el incremento de los rendimientos, la optimización del consumo de insumos (agua de riego, fertilizantes y fitosanitarios), la disminución de los costes operativos y, como consecuencia de todo ello, la mejora de los beneficios económicos de las empresas agrarias (de Martí, 2018).

Además, la práctica de la agricultura de precisión suele reportar mejoras en la seguridad de los trabajadores agrícolas y de las personas ubicadas en las proximidades de las parcelas del cultivo (población diseminada y transeúntes) y también, una mayor prevención de los riesgos de contaminación ambiental (de Martí, 2018).

Este enfoque promueve cultivos más sanos y un apoyo para las técnicas de monitoreo, las cuales suelen implicar cuadrillas de trabajadores inspeccionando las plantas para detectar enfermedades. Proporcionando así, una ayuda a estas labores de campo. Además de tener un impacto en la economía local mediante la reducción en gastos de insumos para los cultivos y en consecuencia mitigando el impacto ambiental que trae consigo la actividad agrícola.

1.6 Alcance

Implementar un diseño experimental para estudiar si existe diferencia significativa en los factores no controlables del cultivo. Para este análisis se necesita de mucho recurso computacional por la cuestión del procesamiento de las imágenes. Debido a que se trabajará con imágenes de dos constelaciones una llamada Sentinel y PlanetScope. El trabajo se llevará a cabo en el Laboratorio de Geomática y Teledetección del Tecnológico Nacional de México – Instituto Tecnológico de Culiacán.

2 FUNDAMENTO TEÓRICO

2.1 Marco conceptual

2.1.1 Agricultura

La palabra agricultura proviene del latín *ager* (campo) y *colo* (cultivar), cuya combinación da como significado labranza del campo o de la tierra (Harris & Fuller, 2014).

El término agricultura abarca las formas en que los cultivos y los animales domésticos contribuyen al sustento de la humanidad, suministrando alimentos y diversos productos esenciales para la población (Harris & Fuller, 2014). En algunas ocasiones, el término se restringe a referirse únicamente a los cultivos, dejando de lado la cría de animales domésticos, aunque generalmente abarca ambas prácticas.

El avance de la agricultura es crucial, especialmente en términos de beneficios sociales y económicos. La agricultura no solo incrementa la producción de alimentos, sino que también eleva los ingresos netos y mejora la productividad de las familias. Además, contribuye a reducir la desigualdad de ingresos entre el empleo agrícola en áreas rurales y los salarios de los trabajadores urbanos en fábricas, lo que a su vez mejora las condiciones de vida de los agricultores (Norasma, y otros, 2019).

2.1.2 Agricultura de precisión

La agricultura de precisión es una estrategia de gestión que reúne, procesa y analiza datos temporales, espaciales e individuales de plantas y animales y los combina con otra información para respaldar las decisiones de gestión de acuerdo con la variabilidad estimada para mejorar la eficiencia del uso de los recursos, la productividad, la calidad, la rentabilidad y la sostenibilidad de la producción agrícola (ISPA, 2024).

Arreguín Jiménez, (2019) menciona que la agricultura de precisión consiste en la gestión de la producción agrícola a partir de la observación, la medida y la forma de resolver cualquier factor que pueda determinar que un cultivo sea exitoso o no, utilizando herramientas que permitan aumentar la rentabilidad de los cultivos, así como su calidad, cantidad y rendimiento.

La AP se define como el uso de un conjunto de técnicas respaldadas por tecnología avanzada para gestionar la producción agrícola de manera específica (Gama Moreno, Plazola Soltero, Murguia Vadillo, López Carrillo , & Martínez Hernández, 2022). Esto proporciona a los responsables de los cultivos una herramienta eficaz para su monitoreo, permitiendo la captura de imágenes que ayudan a detectar de manera temprana enfermedades, plagas, etc.

La innovación tecnológica de la AP permite a los agricultores maximizar los rendimientos de sus cultivos, disminuir el uso excesivo de fertilizantes y pesticidas, conservar los recursos naturales y enfrentar los fenómenos meteorológicos inminentes. Es por ello que, la agricultura de precisión es la práctica agrícola moderna que hace que la producción de cultivos sea más eficiente, a través del uso de las tecnologías de GPS, sensores y satélites (Rosales Soto & Arechavala Vargas, 2020).

2.1.3 Espectro electromagnético

El término "luz" se emplea a menudo como sinónimo de radiación electromagnética, que incluye no solo las longitudes de onda ultravioleta, visible e infrarroja, sino también las de rayos X, gamma y radio. La radiación electromagnética se refiere a la emisión o transferencia de energía en forma de ondas electromagnéticas compuestas por campos eléctricos y magnéticos oscilantes (Zwinkels, 2015).

Dicha radiación se categoriza en dos parámetros: la longitud de onda (λ) y la frecuencia (f) (Figura 2.1). La primera se define como la distancia entre dos crestas sucesivas mientras que la frecuencia representa el número de ciclos qué atraviesan un punto determinado en una unidad de tiempo (Rodrígues Medrano, 2020). Ambos elementos presentan una relación inversa, es decir, a medida que la longitud de onda se acorta la frecuencia aumenta.

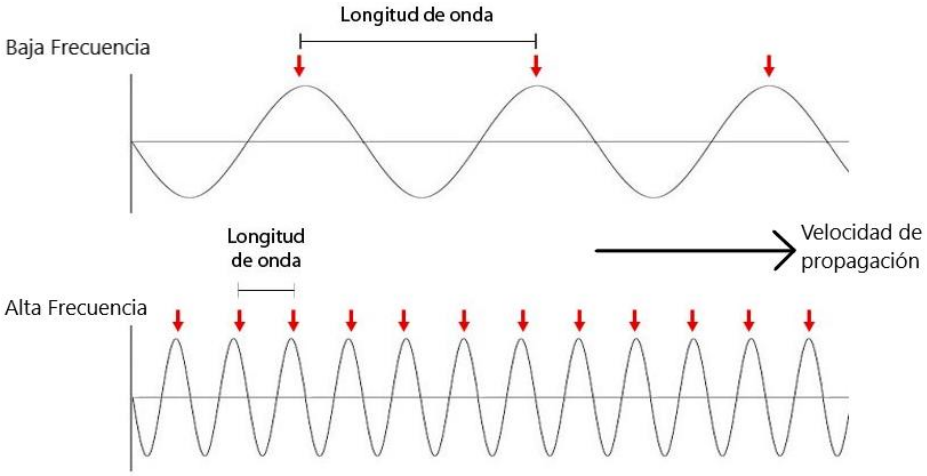

Figura 2.1. Longitud de onda, frecuencia y velocidad de propagación. Fuente: (ESERO Spain, s.f.)

El espectro electromagnético (Figura 2.2) es el conjunto de todas las frecuencias posibles a las que puede generarse radiación electromagnética (Luque Ordóñez, 2012).

Según Cayado Fernández (2014) el espectro incluye una amplia gama de radiaciones, desde las de menor longitud de onda, como son los rayos gamma y los rayos X, pasando por la radiación ultravioleta, la luz “visible” y los rayos infrarrojos, hasta las ondas electromagnéticas de mayor longitud de onda, como son las ondas de la radio.

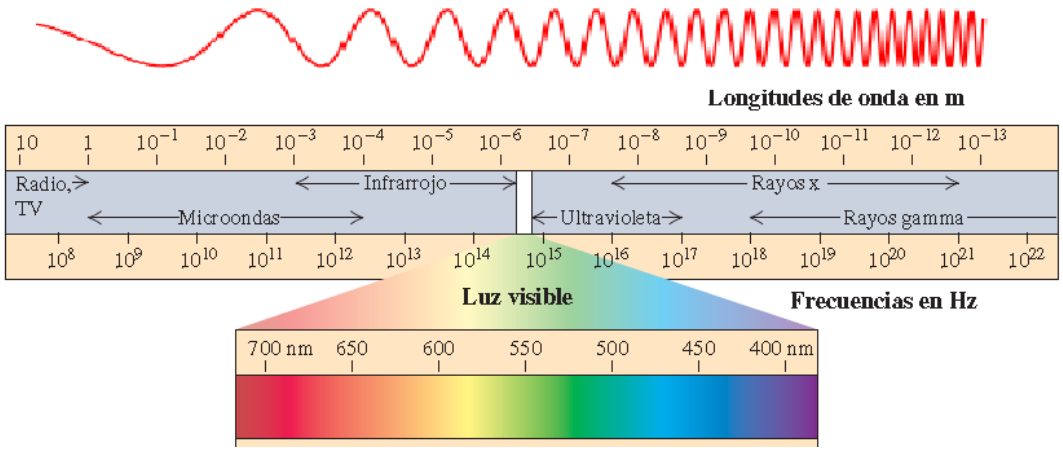

Figura 2.2. Espectro electromagnético. Fuente: (García & Lárez Velásquez, 2020)

2.1.4 Imagen digital

La imagen digital es una representación bidimensional, f (x, y), donde x y y son coordenadas espaciales (planas), y la amplitud de f un par de coordenadas (x, y) representa la intensidad de escala de grises de la imagen en ese punto (Callejas Ramos, 2016).

Las imágenes bidimensionales según (Zaragoza & Bartolucci, 2008) se dividen en dos tipos:

- Imágenes vectoriales, utilizan coordenadas (puntos, líneas o polígonos) para delimitar las formas básicas.
- Imágenes de mapa de bits, se representan mediante una cuadrícula de celdas a las que se les asignan valores. Cada una de estas celdas se denomina píxel (punto), que es una unidad de división sin un tamaño físico específico.

2.1.5 Imagen multiespectral

Las imágenes multiespectrales son un arreglo de columnas y renglones que conforman una matriz de datos numéricos que representan la intensidad de la energía electromagnética reflejada o emitida por los objetos en la superficie de la Tierra (Sánchez Méndez & Arguijo Hernández, 2018).

2.1.6 Ortomosaicos

Con la finalidad de cubrir áreas extensas la cámara debe capturar cientos de imágenes las cuales posteriormente deben ser alineadas y unidas en una sola fotografía para obtener una vista completa, además debe ser corregida geométricamente para que coincida con un sistema de coordenadas geoespacial (Gómez Ortega, 2018).

(Escalante Torrado, Cáceres Jiménez, & Porras Díaz, 2016) definen a un ortomosaico como un mapa que se compone de varias imágenes áreas, las cuales han sido unidas y corregidas para eliminar distorsiones ocasionadas por el relieve del terreno y los objetos en él.

2.1.7 Sistemas de información geográfica

Un sistema de información geográfica (SIG) es un sistema de hardware, software y procedimientos elaborados para facilitar la obtención, gestión, manipulación, análisis, modelado, representación y salida de datos espacialmente referenciados, para resolver problemas complejos de planificación y gestión (Sosa González, 2012).

Un SIG funciona como un sistema idóneo para realizar una representación espacial unida a una base de datos con el fin de lograr una información geográficamente referenciada y ser así un soporte a la decisión que ayude en problemas complejos de planificación y gestión (Rea Sánchez, Maldonado Cevallos, & Villao Santos, 2015).

2.1.8 Índices de vegetación

Los índices de vegetación (IV) son fórmulas matemáticas que integran la reflectancia medida en diversas bandas espectrales para generar un valor que facilita la evaluación del crecimiento de los cultivos, su vigor y otras características de la vegetación, como la biomasa y el contenido de clorofila (Sishodia, Ray, & Singh, 2022).

La evaluación de la actividad vegetativa se fundamenta en los datos derivados de los índices de vegetación, que son métricas cuantitativas basadas en valores digitales que se emplean para mejorar la diferenciación entre el suelo y la vegetación, minimizando el impacto del relieve en la caracterización espectral de las diversas coberturas (Muñoz Aguayo, 2013). Generalmente, un IV se calcula a partir de múltiples valores espectrales que se suman, dividen o multiplican de manera específica para generar un único valor que refleje la cantidad o el vigor de la vegetación en un píxel determinado. Valores elevados en los índices de vegetación indican píxeles que representan vegetación saludable (Rodríguez Herrera, Torres Trejo, & Linares Fleites, 2014).

En el estudio de la vegetación, las bandas más comunes corresponden al espectro visible en la región roja (con longitudes de onda de aproximadamente 0,6-0,7 µm) y al infrarrojo cercano (NIR, en

torno a 0,7-1,4 μm), ya que estas concentran cerca del 90% de la información relacionada con la vegetación (Solymosi, Kövér, & Romvári , 2019). El cálculo preciso se lleva a cabo utilizando los valores digitales de los píxeles presentes en la imagen.

Uno de los primeros IV es *Ratio Vegetation Index* (RVI), este índice se fundamenta en la idea de que las hojas absorben una mayor cantidad de luz roja en comparación con la luz infrarroja (Xue & Su, 2017). Se puede representar matemáticamente como:

$$RVI = \frac{R_{NIR}}{R_{RED}} \qquad (2.1)$$

Según Parra González & Montorio Llovería (2016) la elección de la banda roja se debe a su baja reflectividad, ya que la clorofila absorbe la luz en esta longitud de onda. Por otro lado, en el infrarrojo cercano, se observa una alta reflectividad debido a la estructura de las hojas en condiciones fenológicas óptimas.

El RVI se utiliza de manera extensiva para la estimación y el monitoreo de la biomasa verde, especialmente en áreas con alta densidad de vegetación, dado que este índice muestra una gran sensibilidad hacia la vegetación y una buena correlación con la biomasa vegetal (Xue & Su, 2017). Sin embargo, su efectividad disminuye en coberturas vegetales bajas (menos del 50%), donde los efectos atmosféricos afectan su precisión.

El índice de vegetación verde (GVI) es un índice que se utiliza para monitorear las variaciones en la absorción de clorofila en las plantas. Se enfoca hacia las longitudes de onda utilizadas y su sensibilidad a las condiciones específicas de la vegetación (Uttaruk & Laosuwan, 2017).

$$GVI = \frac{R_{NIR}}{R_{GREEN}} \qquad (2.2)$$

El índice de vegetación diferencial normalizado (NDVI, por sus siglas en ingles), genera valores que oscilan entre -1 y 1. Este índice se fundamenta en el comportamiento radiométrico de las plantas, que depende de la actividad fotosintética y la estructura foliar, reflejando así su vigor. Por lo tanto, los valores del NDVI están relacionados con la energía absorbida o reflejada en diferentes longitudes de onda (Parra González & Montorio Llovería, 2016).

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (2.3)$$

Donde R_{NIR} es la región del infrarrojo cercano (0.8 – 1.1 μm) y R_{RED} es la región del rojo (0.6 – 0.7 μm).

Este índice se ha utilizado con éxito en numerosos estudios abarcando desde el monitoreo de la vegetación y su clasificación hasta la estimación de diversas características vegetales como el contenido de clorofila y nitrógeno o la altura de las plantas (Solymosi, Kövér, & Romvári , 2019).

La vegetación en condiciones óptimas de crecimiento, es decir, cuando está sana y vigorosa, muestra baja reflectancia en la región visible (0.4 a 0.7 µm) debido a la absorción de pigmentos fotosintéticos como clorofilas, xantofilas y carotenos. La alta reflectancia en el infrarrojo cercano (0.7 a 1.3 µm) se atribuye a la estructura del mesófilo, que dispersa la energía. Sin embargo, durante la senescencia y caída de las hojas, la actividad fotosintética disminuye y se pierde humedad, lo que reduce la reflectancia en el infrarrojo y aumenta en las regiones azul, rojo y verde, resultando en un color amarillo (Prado Molina & Prado Morales, 2022).

El NDVI facilita la interpretación y comparación de los datos al minimizar el impacto de factores externos que podrían distorsionar las mediciones. No obstante, no compensa los efectos atmosféricos y tiene un rango dinámico limitado; por lo cual tiende a subestimar la vegetación escasa debido a la influencia del suelo y se satura rápidamente en áreas con alta densidad de vegetación, esto debido a que su fórmula proporciona el mismo peso a la banda del denominador y del numerador (Solymosi, Kövér, & Romvári , 2019).

El *Infrared Percentage Vegetation Index* (IPVI) tiene un rango de valores que va de 0 a 1, este índice busca eliminar los valores negativos presentes en el NDVI (Gunathilaka, 2021). Aunque el IPVI y el NDVI son funcionalmente equivalentes, su algoritmo es el siguiente:

$$IPVI = \frac{R_{NIR}}{R_{NIR} + R_{RED}} \quad (2.4)$$

El Índice GNDVI, también conocido como índice de vegetación de diferencia normalizada verde, es ampliamente utilizado como un indicador del "verdor" de las plantas. Sus valores oscilan entre -1 y

1, donde los rangos de -1 a 0 se relacionan con la presencia de agua o suelo expuesto. Este índice se aplica principalmente en las etapas intermedias y finales del ciclo fisiológico del cultivo (Montero Zapata, 2022).

Según Garcia Cardenas (2018) el GNDVI se asocia con la proporción de radiación absorbida para la fotosíntesis y presenta una correlación lineal con el Índice de área foliar y la biomasa. Por ello, el GNDVI muestra una mayor sensibilidad a la concentración de clorofila en comparación con el NDVI.

Dicho indicador se obtiene se forma similar que el NDVI, pero como se expresa a continuación el GNDVI emplea la banda verde en lugar de la banda roja.

$$GNDVI = \frac{R_{NIR} - R_{GREEN}}{R_{NIR} + R_{GREEN}} \quad (2.5)$$

(Jin, y otros, 2013) señalan que el índice OSAVI (*Optimized Soil Adjusted Vegetation Index*) es un indicador de vegetación diseñado para reducir el impacto del suelo expuesto al evaluar la cobertura vegetal, mejorando la precisión del análisis en áreas con alta reflectancia del suelo o con baja densidad de vegetación.

$$OSAVI = \frac{1.16 * (R_{NIR} - R_{RED})}{R_{NIR} + R_{RED} + 0.16} \quad (2.6)$$

Aquí, el valor constante de 0.16 actúa como un factor de ajuste que mejora la sensibilidad del índice en áreas sombreadas, permitiendo una evaluación más precisa de la vegetación (Zou, Li, & Hu, 2020).

El índice de vegetación de amplio rango dinámico (WDRVI, por sus siglas en ingles), tiene una habilidad para minimizar los efectos de saturación lo hace una herramienta útil en investigaciones sobre áreas donde la vegetación está bien desarrollada y es exuberante, ya que ofrece mediciones más exactas del vigor de las plantas (Cao, Li, Luo, Pan, & Zhang, 2020).

$$WDRVI = \frac{\alpha * R_{NIR} - R_{RED}}{\alpha * R_{NIR} + R_{RED}} \quad (2.7)$$

Por último, tenemos el índice de diferencia normalizada transformado (TNDVI) es un índice utilizado para medir la biomasa y la composición de clorofila en las plantas. A diferencia del NDVI tradicional, que puede presentar valores negativos, el TNDVI está diseñado para producir solo valores positivos, lo que facilita su interpretación y aplicación (Uttaruk & Laosuwan, 2017).

$$TNDVI = \sqrt{\frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} + 0.5} \qquad (2.8)$$

2.1.9 Diseño de experimentos

Un diseño de experimentos (DOE, por sus siglas en inglés) consiste en planificar y realizar una serie de pruebas con el objetivo de generar datos que, al ser analizados estadísticamente, proporcionen evidencia objetiva para responder a las preguntas planteadas por el investigador sobre una situación particular. (Gutiérrez Pulido & de la Vara Salazar, 2008).

Entre todas las herramientas de calidad el DOE destaca por su capacidad para medir hasta en un 95% las soluciones de los problemas. Esto se debe a su objetividad y a su base estadística sólida, lo que los convierte en una herramienta altamente efectiva para la resolución de problemas.

2.1.10 Matriz de diseño

Se define a la matriz de diseño como una tabla que contiene todas las combinaciones posibles de niveles de factores, permitiendo evaluar sistemáticamente los efectos principales e interacciones entre variables (Gutiérrez Pulido & de la Vara Salazar, 2008).

2.1.11 Análisis de varianza

El análisis de varianza (ANOVA) implica descomponer la variación total observada en cada una de las fuentes que la generan, dando oportunidad de estudiar el efecto de uno o más factores sobre una

variable de respuesta (Gutiérrez Pulido & de la Vara Salazar, 2008). Su objetivo es determinar si hay diferencia estadísticamente significativa en el efecto promedio de los factores.

2.1.12 Sensores remotos

Los sensores remotos son dispositivos que recopilan información sobre un objeto, área o fenómeno sin estar en contacto físico directo con ellos. Utilizan la emisión, reflexión o absorción de ondas electromagnéticas para medir variables del entorno desde una distancia (Guzmán Álvarez, González Zuñiga, Sandoval Fernandez, & Calvo Alvarado, 2022).

2.1.12.1 Sentinel-2

Este satélite está equipado con una avanzada cámara multiespectral de alta resolución que cuenta con 13 bandas espectrales; de las cuales cuatro bandas con una resolución espacial de 10 metros, seis bandas de 20 metros y tres bandas de 60 metros, con un ancho de franja orbital de 290 kilómetros, lo cual proporciona una nueva perspectiva sobre la superficie terrestre y la vegetación (Copernicus, 2024). Además, el sensor cuenta con un instrumento multiespectral (MSI) y con una resolución temporal para Sentinel-2 con frecuencia de revisita de 10 días, mientras que la constelación combinada reduce este intervalo a 5 días.

La constelación se basa en dos satélites idénticos (Sentinel 2A y Sentinel 2B) situados en la misma órbita y separados por 180º (INTA Copernicus Relay, 2017).

(Copernicus, 2024) menciona que el primer lanzamiento para Sentinel 2A fue el 23 de junio de 2015 y para Sentinel 2B fue el 7 de marzo de 2017.

2.1.12.2 PlanetScope

PlanetScope es gestionado por Planet, es una constelación compuesta por unos 130 satélites que capturan imágenes diarias de toda la superficie terrestre, con una capacidad de recolección de 200

millones de km² por día con cuatro bandas espectrales (azul, verde, rojo e infrarrojo cercano). Estas imágenes tienen una resolución aproximada de 3 metros por píxel. Su primer lanzamiento fue en 2014 (Planet, 2024).

Este satélite cuenta con tres tipos de instrumentos: Paloma clásica (PS2), Paloma-R (PS2.SD) y Superpaloma (PSB.SD). La disponibilidad de las imágenes fue entre julio de 2014 y el 29 de abril de 2022. para la Paloma-R el período de marzo de 2019 al 22 de abril de 2022 y para el tercer instrumento estuvieron disponibles de mediados de marzo de 2020 hasta el monitoreo actual, respectivamente (Planet, 2024).

2.1.12.3 Vehículos Aéreos No Tripulados

Los Vehículos Aéreos No Tripulados (VANT), comúnmente llamados drones, son esencialmente pequeñas plataformas aéreas las cuales pueden ser operadas desde una ubicación remota o volar de manera autónoma siguiendo rutas preestablecidas mediante un sistema de automatización (Ojeda Bustamante, González Sánchez, Mauricio Pérez, & Flores Velázquez, 2017).

Los drones tienen la capacidad de recolectar datos en distintas bandas del espectro energético con una resolución espacial de hasta 5 centímetros, especialmente en momentos clave para el desarrollo de los cultivos. Esto convierte la información espectral captada por sus sensores en una herramienta valiosa para monitorear los cultivos y tomar decisiones informadas que favorezcan un mejor rendimiento (Ríos Hernández, 2021).

En la AP el uso de un VANT permite generar mapas de los cultivos con alta resolución espacial, ya que a baja altitud minimizan la interferencia atmosférica y la nubosidad no afecta las imágenes capturadas. La información recopilada a través de esta herramienta optimiza el control de las cosechas, mejora la gestión del riego, ayuda a prevenir plagas y permite realizar estimaciones más precisas de la producción (Hernández Sánchez, Ortiz Torres, Sorcia Vázquez, & Rumbo Morales, 2023).

Se resalta la importancia de los drones en investigaciones vinculadas a las Ciencias de la Tierra, debido a que su versatilidad permite incorporar una variedad de accesorios y sensores, como cámaras

ópticas e infrarrojas, equipos de geolocalización y sensores láser. Estos dispositivos facilitan la obtención de datos alta calidad, complementados por el empleo de computadoras y software especializados capaces de procesar grandes volúmenes de información (Rigoberto, Agustín, & Raúl, 2017).

2.2 Marco teórico

2.2.1 Teledetección

La teledetección comprende un conjunto de técnicas que permiten obtener información a distancia sobre un objeto específico en la superficie terrestre. Esta información trasciende lo que puede captar el ojo humano y se obtiene a través de la interacción de tres elementos clave: el sensor, el objeto en estudio y el flujo energético, conocido también como Espectro Electromagnético (Veneros, y otros, 2020).

Los diferentes objetos en la superficie terrestre, como la vegetación, la nieve, los cuerpos de agua y los suelos, reaccionan de manera distinta al flujo de energía incidente, dependiendo de sus características específicas (García Ferrer, 2013). Si los objetos absorben o transmiten una gran cantidad de energía y reflejan poca, los valores registrados por el sensor serán bajos; esto es lo que sucede con las masas de agua en ciertas regiones espectrales del rango visible (verde y rojo). En cambio, si los objetos son altamente reflectivos, el sensor registrará valores altos. Esto se observa en las masas vegetales en el infrarrojo cercano, en las capas de nieve o en suelos expuestos de origen calizo dentro de la región espectral visible (Botana & Fernández, 2019).

El avance de la teledetección ha sido posible gracias a la mejora en la capacidad de procesamiento y análisis de datos, especialmente a través del uso de SIG. Estos sistemas amplían las opciones para el tratamiento de datos, simplifican los procedimientos y aumentan la potencia y velocidad de las plataformas de procesamiento, lo que permite abordar problemas más complejos (García Ferrer, 2013). Además, hace posible comprender la actividad vegetal mediante los IV, lo que permiten identificar

variaciones en la condición del cultivo, presencia de plagas y características del suelo. De este modo, las técnicas de teledetección proporcionan información precisa sobre la superficie terrestre y las condiciones atmosféricas (Khanal, Fulton, Shearer, Özkan, & Kansas , 2020).

Esta técnica es empleada para monitorear los recursos terrestres mediante tecnologías espaciales, complementadas con observaciones desde la superficie lo que permite alcanzar un alto nivel de precisión y exactitud (Shanmugapriya, Rathika, Ramesh, & Janaki, 2019). Una de las principales ventajas de la teledetección es su capacidad para ofrecer información repetitiva sin necesidad de realizar un muestreo destructivo del cultivo, lo que la convierte en una herramienta valiosa para aplicaciones en la agricultura de precisión (Shanmugapriya, Rathika, Ramesh, & Janaki, 2019).

Las imágenes satelitales proporcionan una visión singular de la Tierra, sus recursos y el efecto que las actividades humanas tienen sobre ella. Dentro de un área determinada, es posible identificar diferentes patrones espaciales, y las imágenes satelitales son fundamentales para este proceso de reconocimiento. Estas imágenes son una herramienta valiosa para recopilar información sobre fenómenos u objetos, y se generan a través de sensores ubicados en plataformas espaciales (Pineda Pastrana, 2011).

La percepción remota (PR), también conocida como teledetección, es un campo científico y tecnológico que facilita la creación, captura, procesamiento y análisis de imágenes, así como de otros datos físicos de la Tierra. Estos datos se obtienen a través de sensores ubicados en el espacio, en aeronaves y mediante dispositivos que realizan mediciones directamente en el lugar (CentroGeo, 2024).

La PR implica la identificación de objetos basándose en las variaciones de la energía reflejada, se pueden alcanzar diferentes niveles de información o resoluciones que facilitan el análisis de los objetos en cuestión, ya sea con mayor o menor grado de detalle. (Huerta García, 2022) menciona que los niveles de resolución de la información son:

- La resolución espacial se refiere al tamaño mínimo de un objeto o característica del terreno que puede ser identificado en una imagen, el cual está determinado por el tamaño del píxel dentro de una imagen.

- La resolución espectral, esta característica se relaciona con las longitudes de onda que el sensor es capaz de medir en micras, y el número de bandas refleja cómo se mide la reflectancia en diversas longitudes de onda. Por ejemplo, un sensor multiespectral con cuatro bandas mide la energía en cuatro longitudes diferentes.
- Resolución temporal es la frecuencia con la que el satélite sobrevuela un mismo punto de la superficie de la Tierra, permitiendo identificar las variaciones que han tenido lugar en una misma área.
- Resolución radiométrica se presenta como una sensibilidad específica a la intensidad de la radiación electromagnética que reflejan. Esta sensibilidad se mide mediante la resolución radiométrica, cuyas unidades se expresan en bits. Un mayor número de bits permite captar una gama más amplia de intensidades de respuesta en una imagen.

2.3 Estado del arte

En el ámbito de la agricultura de precisión, el análisis de imágenes se emplea para estimar métricas de cultivos, desarrollar planes de tratamiento y facilitar la toma de decisiones. Ghazal, Munir, & Qureshi (2024) exploró el procesamiento de imágenes con el objetivo de obtener información valiosa a partir de ellas. También menciona que la creación de ortomosaicos, la extracción de características, la segmentación de plantas, el reconocimiento de objetos y la clasificación pueden ser aplicadas para evaluar diversas propiedades clave del suelo, las cuales pueden ser utilizadas por los agricultores para tomar decisiones informadas acerca de la cantidad de fertilizante requerida y para planificar adecuadamente los programas de riego.

En el monitoreo de cultivos los VANTs se convierten en una herramienta esencial para recopilar datos detallados de los cultivos de manera rápida y precisa, (Chávez Martínez, 2022) con ayuda de un VANT y una cámara externa realizó un estudio sobre los índices de vegetación en un cultivo de tomate Cherry estas herramientas le fueron útiles para identificar una insuficiencia de clorofila y áreas vacías

dentro del cultivo, además evidencia que los IV son de gran ayuda para la detección de afectaciones de tipo nutricional o enfermedades en los cultivos.

Según González, Amarillo, Amarillo, & Sarmiento (2016) métodos como la teledetección y la fotogrametría facilitan la identificación de áreas aptas para el cultivo según las características del suelo, así como la selección del tipo de cultivo más adecuado y el seguimiento de su crecimiento en cada fase. Esto contribuye a tomar decisiones informadas en momentos críticos para optimizar la calidad. Asimismo, el acceso a imágenes satelitales gratuitas, drones económicos y sensores avanzados permite obtener información de alta resolución para evaluar el estado del terreno, detectar problemas y estimar con precisión la productividad futura.

Takalloo, (2024) presentaba como propósito aumentar la precisión y la robustez en la detección de estrés hídrico en cultivos de papa, utilizando modelos avanzados aplicados a conjuntos de datos de imágenes RGB y multiespectrales, que incluyen el uso del infrarrojo cercano (NIR) y las bandas de borde rojo. Las conclusiones más relevantes muestran mejoras notables en la capacidad de detección al integrar datos multiespectrales, estas técnicas de imagen ofrecen información valiosa sobre la salud de las plantas al captar datos que van más allá del espectro visible, lo que resulta especialmente útil para identificar los primeros indicios de estrés hídrico.

3 DESCRIPCIÓN DE ACTIVIDADES

3.1 Delimitación del área de estudio

El área de estudio se ubica en el municipio de Elota, en el estado de Sinaloa, México. El lugar se encuentra en las coordenadas 24° 0'32.71"N y 106°53'8.26"O (Figura 3.1). El estudio fue realizado en los meses de noviembre del 2023 a marzo del 2024.



Figura 3.1. Localización del área de estudio.

3.2 Tipo y condición del cultivo

Se llevo a cabo la experimentación utilizando el cultivo de chile morrón (*Capsicum annumm*), en la Figura 3.2 podemos observar el manejo del cultivo realizado de manera local y como se sostiene

verticalmente con hilos de nailon para mantener las plantas organizadas. Además, se utilizan plásticos en la parte inferior para conservar la humedad.

El área esta delimitada por dos variedades de chile: chile Percheron (polígono M1, M2) y chile Hassium (polígono M3, M4). En la Figura 3.3 se ilustran las divisiones de la parcela, donde los polígonos M1 y M3 corresponden a cultivos con insumos orgánicos, mientras que M2 y M4 son los cultivos testigo.



Figura 3.2. Cultivo de chile morrón (*Capsicum annumm*).

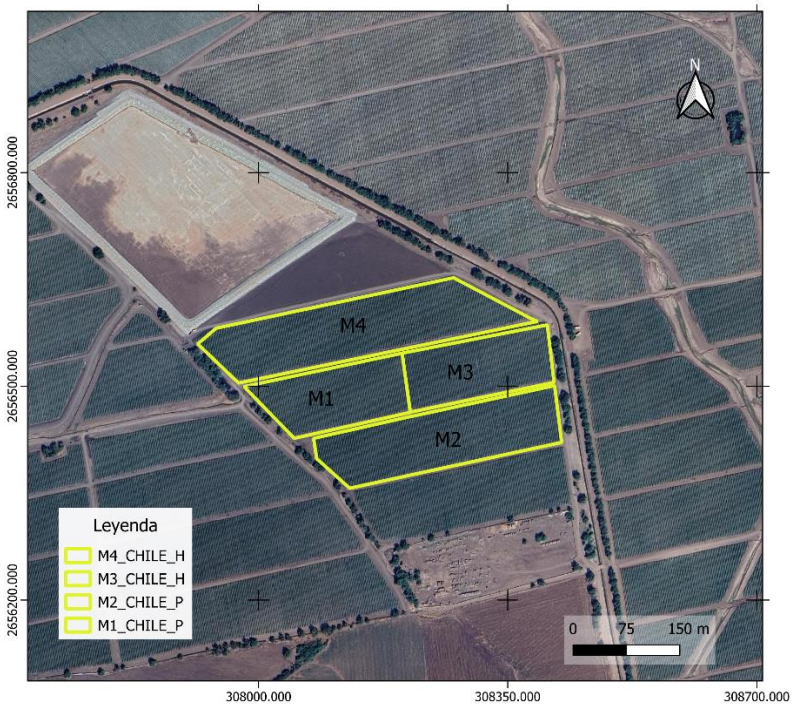

Figura 3.3. División de la parcela donde M1, M3 son cultivos orgánicos y M2, M4 corresponden a los cultivos testigo.

3.3 Imágenes obtenidas con el dron

Para el proceso de obtención de las imágenes multiespectrales se hizo uso de un VANT Phantom 4, el cual fue equipado con una cámara (MAPIR Survey 3W) anclada a través de una base externa (Figura 3.4). Esta cámara permite obtener imágenes en un rango espectral que incluye los colores rojo, verde e infrarrojo cercano (RGN).

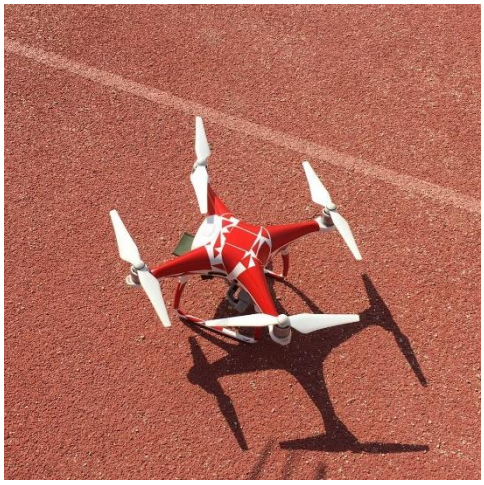

Figura 3.4. Phantom 4 Pro. Fuente: Fotografía propia

Las imágenes obtenidas poseen una resolución radiométrica de 12 bits, lo que significa que cada píxel en una única banda puede diferenciar 4,096 niveles distintos de reflectancia. Al combinar las tres bandas espectrales, se pueden representar hasta 68,719,476,736 valores diferentes para el píxel final.

La configuración de la cámara se llevó a cabo de manera independiente y tomando en cuenta los parámetros definidos en el VANT. Las características de la cámara se encuentran en la Tabla 3.1.

Tabla 3.1. Características de la cámara MAPIR

Características de la cámara	
Resolución	12 Mpx (4000 x 3000 px)
Óptica de lentes	87° HFOV (19 mm) f/2.8 apertura -1% distorsión extremadamente baja (no ojo de pez) lente de vidrio.
GSD (*Ground Sample Distance)*	5.5 cm/px a 120 m
Sensor	Sony ExmorR IMX117 12 ¿MP (Bayer RGB)
GPS/GNSS (externos)	Ublox UBX-G7020-KT
Intervalos de captura	0.5 s, 1 s, 2 s, 5 s, 10 s, 30 s, 1 min, 5 min, 10 min, 30 min, 1hr, 2 hrs, 6 hrs, 12 hrs, y 24 hrs.

Las imágenes de los ortomosaicos que fueron proporcionadas se realizaron con la ayuda del software Agisoft Metashape (1.7.3).

3.4 Acceso de las plataformas satelitales

Como primera actividad, con el fin de tener acceso a las imágenes satelitales, se hizo el registro en las plataformas correspondientes de Copernicus y Planet (Sentinel-2 y PlanetScope) para obtener el acceso gratuito. Posteriormente se procedió a la descarga de las imágenes satelitales. Dichas imágenes se descargaron con fechas cercanas a los vuelos obtenidos del cultivo monitoreado (Tabla 3.2), el cual fue realizado en un cultivo de chile morrón (*Capsicum annumm*) haciendo uso de un dron para la captura de imágenes.

Tabla 3.2. Fechas de los vuelos con VANT y fechas de las imágenes descargadas de Copernicus y Planet

Vuelo	Copernicus	Planet	Vant
	Fecha	Fecha	Fecha
1	30/10/2023	29/10/2023	29/10/2023
2	01/11/2023	01/11/2023	05/11/2023
3	24/11/2023	28/11/2023	26/11/2023
4	16/12/2023	17/12/2023	17/12/2023
5	08/01/2024	07/01/2024	07/01/2024
6	28/01/2024	28/01/2024	28/01/2024
7	17/02/2024	19/02/2024	18/02/2024
8	18/03/2024	18/03/2024	18/03/2024

3.5 Preparación de imágenes satelitales

El procesamiento de las imágenes satelitales para ambas constelaciones se realizó en el software QGIS (3.36.3). Se utilizó la herramienta de calculadora ráster para adquirir ocho índices de vegetación (Tabla 3.3). De los cuales, se extrajeron los cuatro polígonos del cultivo estudiado (Figura 3.3), esto último haciendo uso de la herramienta cortar ráster por capa de máscara. Posteriormente se

extrajo el promedio y la desviación estándar de la información de las áreas de estudio para realizar un análisis estadístico.

Tabla 3.3. Índices de vegetación con su respectiva ecuación

Índice de vegetación	Ecuación
Ratio Vegetation Index (RVI)	$RVI = \frac{R_{NIR}}{R_{RED}}$
Green Vegetation Index (GVI)	$GVI = \frac{R_{NIR}}{R_{GREEN}}$
Normalized Defference Vegetation Index (NDVI)	$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$
Infrared Percentage Vegetation Index (IPVI)	$IPVI = \frac{R_{NIR}}{R_{NIR} + R_{RED}}$
Green Normalized Defference Vegetation Index (GNDVI)	$GNDVI = \frac{R_{NIR} - R_{GREEN}}{R_{NIR} + R_{GREEN}}$
Optimized Soil-Adjusted Vegetation Index (OSAVI)	$OSAVI = \frac{1.16 * (R_{NIR} - R_{RED})}{R_{NIR} + R_{RED} + 0.16}$
Wide-Dynamic-Range Vegetation Index (WDRVI)	$WDRVI = \frac{\alpha * R_{NIR} - R_{RED}}{\alpha * R_{NIR} + R_{RED}}$
Transformed Normalized Difference Vegetation Index (TNDVI)	$TNDVI = \sqrt{\frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} + 0.5}$

El proceso fue el mismo para ambas plataformas, cabe destacar que la única diferencia notoria fue al momento de insertar las imágenes. Debido a que para las imágenes de Sentinel-2 fue necesario hacer uso de la herramienta *image conversion* del complemento SCP (*Semi-Automatic Classification Plugin*) del mismo software para obtener las bandas espectrales necesarias para el cálculo de los índices, mientras que las imágenes de PlanetScope ya estaban en el formato necesario.

3.6 Clasificación de los pixeles con los ortomosaicos de los vuelos del dron

Se realizó una clasificación supervisada de los pixeles tomando en cuenta las clasificaciones de planta, suelo, sombra, plástico y hierba, para poder obtener una máscara binaria la cual contiene solo dos clasificaciones: el valor 0 que representa suelo y el valor 1 que corresponde a las plantas, esto se realizó para obtener datos que representen únicamente plantas.

Para este proceso de clasificación, primero se empleó la calculadora ráster para generar la máscara binaria y solo obtener la clasificación de “planta”, de esta forma se realizó una máscara binaria por fecha de vuelo. Una vez obtenida dichas máscaras se aplicó la herramienta cortar ráster por capa de máscara. Esto permitió extraer cada polígono del área de estudio que corresponde a las dos variedades de chile morrón presentes en el análisis.

Una vez hecha la clasificación de las imágenes se utilizó el lenguaje de programación R en su entorno de desarrollo RStudio para extraer los datos estadísticos de los índices de vegetación. Se hizo uso de las librerías *sp* y *raster* para las operaciones.

3.7 Análisis estadístico

Prueba de diferencia de medias

Se inició con una prueba de diferencia entre media para muestras grandes, porque el tamaño de la muestra para cada sensor es mayor que 30 pixeles (Levin & Rubin, 2004). Para esta prueba se debe plantar una hipótesis nula (H_0) la cual describe que no hay diferencia entre las medias. Esta hipótesis se mantiene como valida a menos que los datos muestren evidencias suficientes para descartarla, lo cual da oportunidad a la hipótesis alternativa (H_1) quien representa lo contrario a la hipótesis anterior.

Por el tamaño de la muestra se utilizó una distribución normal con un nivel de significancia de 0.05 ($\alpha = 0.05$) el cual representa la probabilidad de rechazar la hipótesis nula bajo la suposición de que esta es verdadera, lo cual denominaríamos error tipo 1 (Levin & Rubin, 2004). En la Figura 3.5 se puede observar que el nivel de significancia se divide en dos áreas específicas, cada una representando

una fracción de 0.025 del área total. La región de aceptación se compone de dos áreas iguales, cada una abarcando 0.475 del área total.

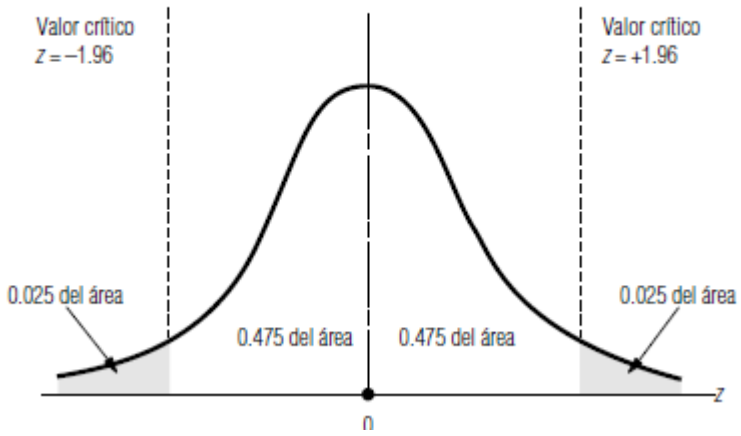

Figura 3.5. Distribución normal de la diferencia entre dos medias a un nivel de significancia de 0.05. Fuente: (Levin & Rubin, 2004)

También se obtuvo la media y la desviación estándar de los conjuntos de datos que queremos comparar entre sí. Posteriormente se calculó el error estándar de la diferencia entre las dos medias.

$$\hat{\sigma}_{\bar{x}_1-\bar{x}_2} = \sqrt{\frac{\hat{\sigma}_1^2}{n_1} + \frac{\hat{\sigma}_2^2}{n_2}} \qquad (3.1)$$

A continuación, se hizo la estandarización la diferencia de las medias, $\bar{x}_1 - \bar{x}_2$. Como se esta en el supuesto de que $\mu_1 = \mu_2$, la diferencia hipotética de las medias $(\mu_1 - \mu_2)H_0$ se elimina, entonces se divide entre $\hat{\sigma}_{\bar{x}_1-\bar{x}_2}$, el error estándar entre la diferencia de las medias muestrales. Obteniendo la formula siguiente.

$$Z = \frac{\bar{x}_1-\bar{x}_2}{\hat{\sigma}_{\bar{x}_1-\bar{x}_2}} \qquad (3.2)$$

Se comparó el valor crítico el cual fue calculado con la herramienta Excel mediante la función $DISTR.NORM.ESTAND.INV(0.025)$ contra el valor del estadístico de prueba (valor Z). Para esto valores se aplica la regla de decisión la cual establece que la hipótesis nula se rechazará siempre que el valor del estadístico de prueba sea superior al valor crítico, lo que colocaría al valor del estadístico de prueba

en la zona de rechazo (Figura 3.6). Por el contrario, si el valor del estadístico de prueba es menor que el valor critico no se rechazará la hipótesis nula, considerándola válida y colocándola dentro de la zona de aceptación.

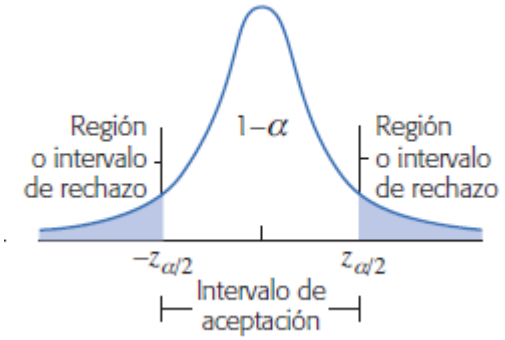

Figura 3.6. Región de rechazo y de aceptación para hipótesis. Fuente: (Gutiérrez Pulido & de la Vara Salazar, 2008)

Análisis de varianza (ANOVA)

Debido a que la prueba de diferencia de medias puede proporcionar un valor de prueba muy elevado debido a que los datos presentan una desviación estándar muy baja. Es por esto por lo que se optó por aplicar un análisis de varianza (ANOVA) multifactorial con el objetivo de probar las hipótesis de interés y poder determinar si existe diferencia estadísticamente significativa entre las medias de los sensores.

Para este proceso con ayuda de Excel se construyó una matriz de diseño, que incluye una variable de respuesta (variable dependiente) que representa los promedios obtenidos por cada sensor, y tres factores (variables independientes) que son la especie de chile, fecha (vuelo) y el sensor. Además, cada factor presenta diferentes niveles, el primero tiene cuatro niveles (M1, M2, M3 y M4), el segundo tiene ocho (V1, V2, V3, V4, V5, V6, V7, V8) y el tercero tiene tres (Sentinel-2, PlanetScope, Dron).

Se hizo uso del software Statgraphics donde se transcribió la matriz de diseño y se realizó el ANOVA multifactorial (Tabla 3.4). Además, se efectuó una prueba de diferencia de medias (LSD por sus siglas en inglés) esto con el fin de comparar los niveles de los factores que resultaron estadísticamente significativos entre sí en la tabla ANOVA.

Tabla 3.4 Fórmulas para ANOVA multifactorial

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrado medio	F-Calculada
Factor (es)	$SSA = \sum_{I=1}^{a} n_i \ (\overline{y}_i - \overline{\overline{y}})^2$	$K - 1$	$CMA = \frac{SSA}{K-1}$	$F - Cal = \frac{CMA}{CME}$
Error	$SSE = SST - SSA$	$n - K$	$CME = \frac{SSE}{n-K}$	
Total	$SST = \sum_{i=1}^{a}\sum_{i=i}^{n}(\overline{y}_{ij} - \overline{\overline{y}})^2$	$n - 1$		

La comparación de medias (Tabla 3.5) contiene los valores decisivos para demostrar si las medias son estadísticamente iguales o no. Para este efecto se toma en cuenta el criterio de sí el valor absoluto de la diferencia de medias es mayor o igual que la prueba LSD no tengo elementos estadísticos para decir que las medias son iguales, por otro lado, si dicho valor absoluto es menor que el valor LSD podemos decir que las medias son iguales.

Tabla 3.5. Comparación de medias

Diferencia de medias	Calculo	LSD
Sensor 1 – Sensor 2	$\lvert\mu_1 - \mu_2\rvert$	$LSD = \left[t_{(\alpha/2, n-K)}\right]\sqrt{\frac{2CME}{b}}$

Para finalizar se hizo la representación gráfica de las medias mediante intervalos de confianza para cada factor.

$$Intervalo\ de\ confianza = \mu \pm \left[t_{(\alpha/2, n-K)}\right]\sqrt{\frac{2CME}{b}} \qquad (3.3)$$

Es relevante destacar que, si los intervalos de confianza no se superponen en el gráfico, se puede concluir que los factores son distintos entre sí. Sin embargo, si alguno de los intervalos se superpone con otro, esto indica que estadísticamente hablando son iguales.

4 RESULTADOS

4.1 Adquisición de imágenes mediante dron

Las imágenes RGN (rojo, verde, infrarrojo) se obtienen con el apoyo de un VANT adaptado para sostener la cámara. Así, la cámara opera de manera autónoma respecto al VANT. En este sentido, los parámetros del plan de vuelo se establecieron considerando las especificaciones de la cámara MAPIR. Las Tablas 4.1 y 4.2 indican los parámetros óptimos de configuración de vuelo y de la cámara necesarios para alcanzar la resolución previamente definida.

Tabla 4.1. Parámetros del vuelo con la cámara RGN.

Parámetros de vuelo	
Velocidad	3.2 m/s
Altura	40 m
Tiempo de captura	1 seg
Solapamiento longitudinal	94%
Solapamiento transversal	75.4%
GSD (Gr*ound Sample Distance)*	1.83 cm/px

Tabla 4.2. Configuración de los parámetros de la cámara de los vuelos efectuados

Parámetros de la cámara	
Tiempo de captura	1 seg
Tamaño de la imagen	12 mpx
GSD (*Ground Sample Distance*)	1.83 cm

4.2 Generación de ortomosaicos

Para iniciar con la supervisión del cultivo de Chile morrón, se obtuvieron los ortomosaicos para los ocho vuelos del dron. Las imágenes capturadas sobre el cultivo contienen las bandas del rojo, verde e infrarrojo cercano. En la Figura 4.1 se puede observar como ejemplo el ortomosaico que se adquirió para el vuelo 6. En el Anexo 8.1 se muestran los ortomosaicos obtenidos para los vuelos restantes del VANT.

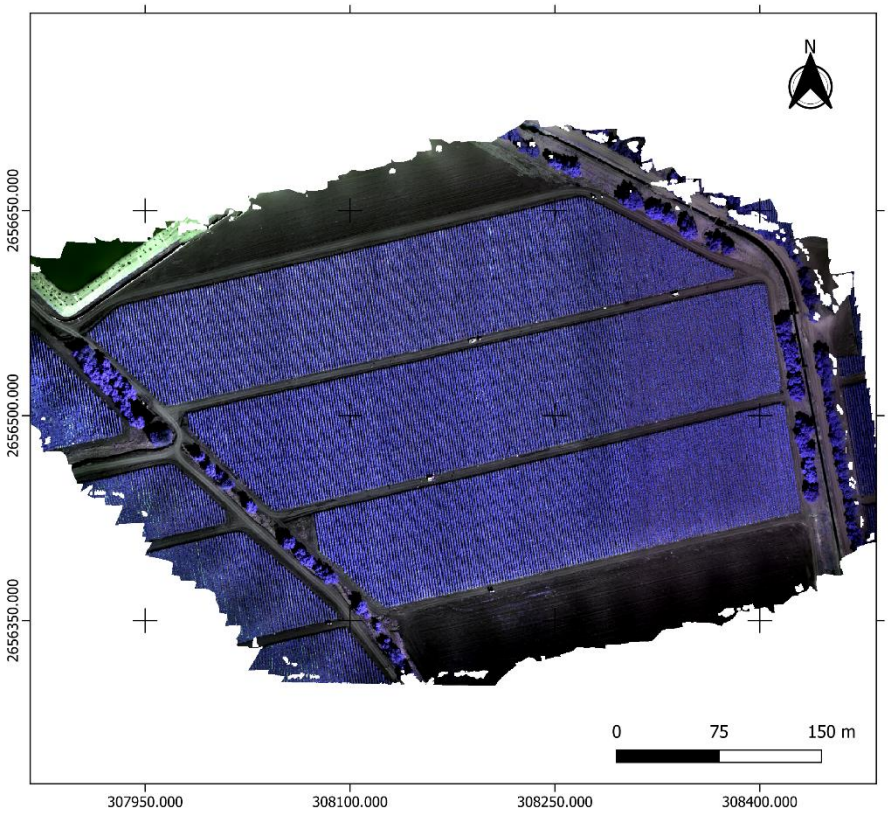

Figura 4.1. Ortomosaico del vuelo 6 con fecha 28/01/24.

Complementando, en la Tabla 4.3 se presenta un número total de 7 vuelos efectuados en las fechas correspondientes, utilizando datos recopilados en el momento de cada vuelo. Cabe destacar que el V1 no pudo finalizarse correctamente, siendo este el motivo por el que empieza directamente con el V2.

Tabla 4.3. Bitácora de las imágenes obtenidas con la cámara multiespectral (RGN).

Vuelo	Fecha	Hora	Condiciones climáticas	Observaciones de la planta
V2	05/11/2023	9:40 am	Cielo parcialmente nuboso. Temperatura 29 °C.	-
V3	26/11/2023	9:35 am	Nuboso. Temperatura 24 °C.	Con flor y presenta frutos verdes
V4	17/12/2023	9:40 am	Despejado. Temperatura 28 °C.	-
V5	07/01/2024	9:50 am	Con nubosidad al inicio del muestreo, con cielo despejado al termino. Temperatura 22 °C.	Presenta flor, frutos rojos y empieza la cosecha
V6	28/01/2024	10:00 am	Cielo despejado. Temperatura 21 °C.	Cosechando
V7	18/02/2024	9:45 am	Cielo despejado, con un poco más de viendo de lo habitual. Temperatura 23 °C.	Se observan lonas amarillas para control de plagas, fumigando en el momento del muestreo
V8	18/03/2024	9:50 am	Cielo despejado. Temperatura 25 °C.	Chiles verdes, rojos y secos. Aun presenta flor

4.3 Cálculo de los índices espectrales mediante las imágenes del dron

La Figura 4.2 representa la imagen de los cuatro polígonos del cultivo de chile morrón para el vuelo 2 con fecha 05/11/23, dicha imagen cuenta con una clasificación supervisada, la cual ayudo a eliminar pixeles que no representaran planta.

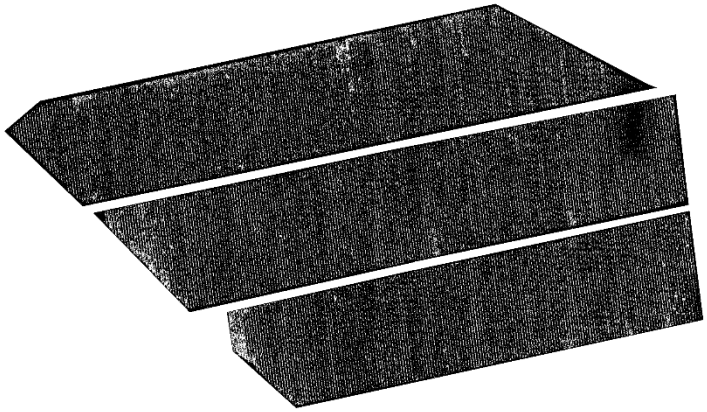

Figura 4.2. Mascara binaria para el vuelo 1 de la fecha 05/11/23

Con ayuda de un código programado en R (Anexo 8.2) se facilitó la obtención del promedio y desviación estándar para cada uno de los índices.

A continuación, se presenta un extracto como ejemplo del código para la obtención de los datos estadísticos aplicando la máscara binaria mostrada en la Figura 4.2. De inicio se abren las librerías necesarias y se llama la máscara binaria como raster, se especifica que todos los valores de 0 representen NA.

```
library(sp)
library(raster)
PLANT_M1<-raster("D:\\02_CLASIFICACION\\00_MASCARA_PLANTA\\MASC_M1_261123.tif")
PLANT_M1[PLANT_M1==0]<-NA
```

Enseguida se importa el índice y se multiplica por la máscara binaria. Una vez efectuada la operación, se calcula la media y la desviación estándar.

```
#POLIGONO M1

RVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\RVI_261123.tif")

RVI_M1_261123<-resample(RVI_M1_261123,PLANT_M1)

RVI_M1_261123_m<-(RVI_M1_261123*PLANT_M1)

prom<-(RVI_M1_261123.prom<- data.frame(RVI_M1_261123.mean=cellStats(RVI_M1_261123_m,
"mean")))

desv<-(RVI_M1_261123.desv<-data.frame(RVI_M1_261123.sd=cellStats(RVI_M1_261123_m,
"sd")))
```

En la Tabla 4.4 se muestran las medias y desviaciones estándar obtenidas para cada índice de vegetación del vuelo 2 con fecha 05/11/23, estos datos fueron obtenidos para cada uno de los 6 vuelos restantes; pero para un mejor manejo de los valores se realizó un promedio general entre los cuatro polígonos de cada vuelo, aplicándose a los ocho índices de vegetación.

Tabla 4.4. Medias y desviaciones estándar para el vuelo 2 con fecha 05/11/23.

Fecha:05/11/23									
Número de vuelo	**Índices**	**M1**		**M2**		**M3**		**M4**	
		$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S
V1	RVI	1.737	0.127	1.724	0.135	1.718	0.132	1.728	0.129
	GVI	1.469	0.153	1.453	0.166	1.424	0.155	1.428	0.149
	NDVI	0.268	0.037	0.264	0.039	0.262	0.038	0.265	0.037
	IPVI	0.634	0.018	0.632	0.019	0.631	0.019	0.633	0.019
	GNDVI	0.187	0.053	0.181	0.059	0.171	0.056	0.173	0.053
	OSAVI	0.310	0.042	0.306	0.045	0.304	0.045	0.308	0.043
	WDRVI	-0.704	0.019	-0.706	0.020	-0.707	0.020	-0.706	0.019
	TNDVI	0.876	0.021	0.874	0.023	0.873	0.022	0.874	0.022

4.4 Imágenes satelitales

Una vez delimitada el área del cultivo de chile morrón y con base en la Tabla 3.2 las fechas de adquisición de las imágenes trataron de ser lo más cercana posible a los vuelos que se realizaron en campo a fin de que los resultados fueran comparables. Se seleccionó la imagen más limpia, es decir, aquella imagen que sea clara y que preferentemente no contenga nubosidad. Este proceso se implementó para ambos sensores.

En la Figura 4.3 se tomó como ejemplo el vuelo 2 del dron con fecha 05/11/23. En base a las imágenes resultantes de la búsqueda podemos observar que la imagen del 4 de noviembre contiene un porcentaje de nubosidad más alto en comparación con la fecha del 01 de noviembre. Es por esto por lo que para el vuelo 2 del sensor PlanetScope se descargó la imagen con fecha 01/11/23. En la Figura 4.4 podemos observar un proceso similar, pero para la constelación de Copernicus, la única diferencia es que en esta fue necesario seleccionar el sensor con el que se trabajó, en este caso Sentinel-2.

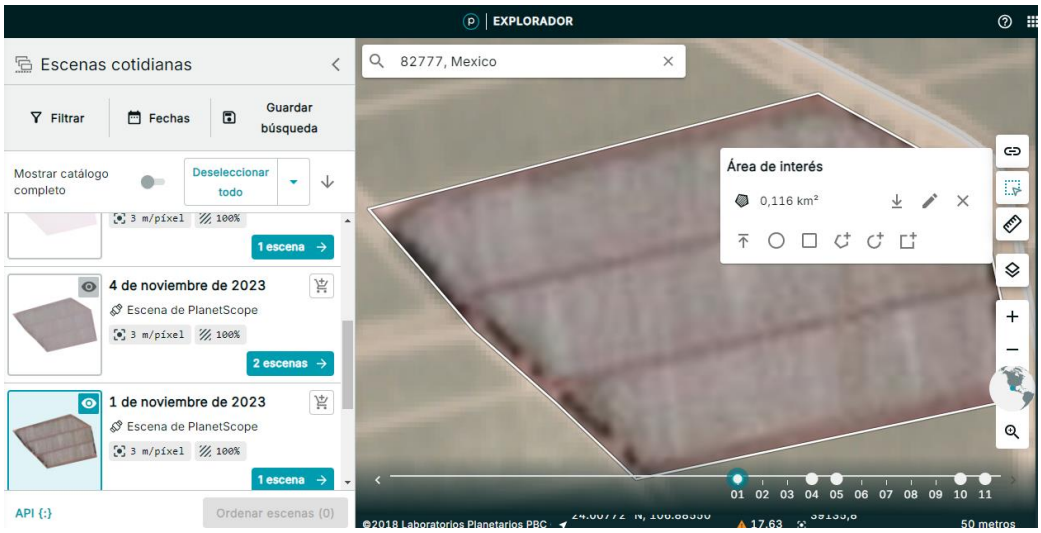

Figura 4.3. Descarga de imágenes en Planet Explorer.

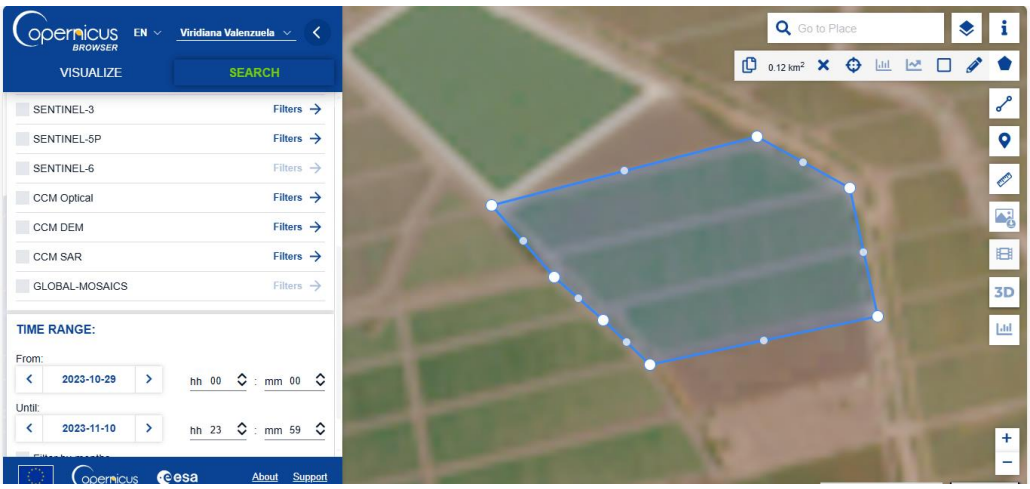

Figura 4.4. Plataforma Copernicus para descarga de imágenes de Sentinel-2.

A continuación, en la Figura 4.5a se presentan las imágenes resultantes para PlanetScope y la Figura 4.5b para Sentinel-2. Dichas imágenes están cortadas en base al área de estudio.

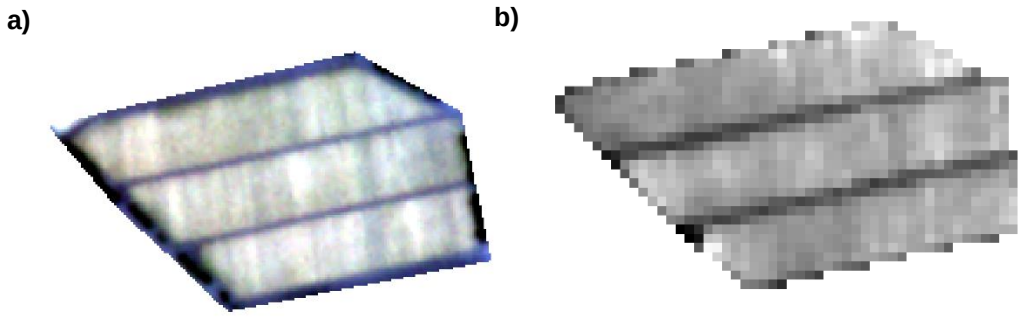

Figura 4.5. a) área de estudio para el V1 de PlanetScope b) área de estudio para la imagen del V1 de Sentinel-2.

4.5 Obtención de índices espectrales para imágenes satelitales

La Tabla 4.5 contiene la media y la desviación estándar para los índices de vegetación del V7 con fecha 17/02/24 del sensor Sentinel-2, mientras que la Tabla 4.6 muestra los valores estadísticos obtenidos para el V6 28/01/24 del sensor de PlanetScope. Para facilitar el manejo de los valores para

el análisis estadístico, se calculó un promedio general entre los cuatro polígonos de cada vuelo, aplicándolo a los ocho índices de vegetación.

Tabla 4.5. Media y desviación estándar para vuelo 7 de Sentinel-2.

Fecha:17/02/24									
Número de vuelo	**Índices**	**M1**		**M2**		**M3**		**M4**	
		$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S
V7	RVI	9.110	2.051	9.890	2.492	7.590	1.354	6.061	1.091
	GVI	7.375	0.886	7.557	1.009	6.446	0.596	5.601	0.586
	NDVI	0.791	0.058	0.803	0.063	0.761	0.044	0.709	0.051
	IPVI	0.895	0.029	0.901	0.032	0.880	0.022	0.855	0.026
	GNDVI	0.758	0.030	0.762	0.035	0.730	0.024	0.694	0.029
	OSAVI	0.614	0.060	0.634	0.064	0.602	0.045	0.549	0.052
	WDRVI	-0.060	0.128	-0.023	0.144	-0.144	0.092	-0.251	0.088
	TNDVI	1.136	0.026	1.141	0.029	1.123	0.020	1.099	0.024

Tabla 4.6. Media y desviación estándar para vuelo 6 de PlanetScope.

Fecha:28/01/24									
Número de vuelo	**Índices**	**M1**		**M2**		**M3**		**M4**	
		$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S	$\bar{x}$	S
V6	RVI	5.956	0.410	6.457	0.623	5.479	0.463	4.611	0.378
	GVI	5.587	0.276	5.863	0.388	5.206	0.318	4.679	0.263
	NDVI	0.711	0.017	0.730	0.023	0.690	0.022	0.642	0.024
	IPVI	0.856	0.009	0.865	0.011	0.845	0.011	0.821	0.012
	GNDVI	0.696	0.013	0.708	0.017	0.677	0.017	0.647	0.016
	OSAVI	0.825	0.020	0.847	0.026	0.800	0.026	0.745	0.027
	WDRVI	-0.254	0.032	-0.217	0.046	-0.293	0.039	-0.370	0.035
	TNDVI	1.101	0.008	1.109	0.010	1.091	0.010	1.069	0.011

En la Figura 4.6 se muestra como ejemplo representativo la imagen de los cuatro polígonos del índice NDVI para el V6 del sensor PlanetScope, donde podemos observar las diferentes variaciones en la reflectividad de la planta. Las zonas con color azul representan planta con mejores condiciones.

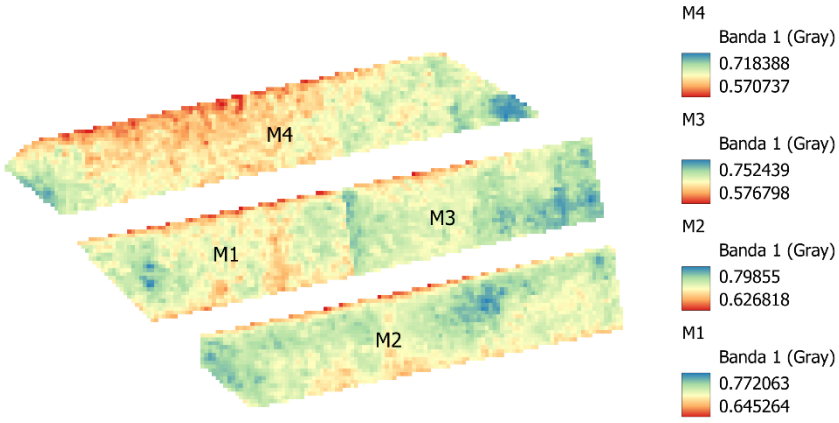

Figura 4.6. Índice de vegetación NDVI para el vuelo 6 de PlanetScope.

4.6 Análisis estadístico

4.6.1 Prueba para diferencia entre medias de muestras grandes

Para esta comparación se plantearon las siguientes hipótesis, en las cuales μ_1 representa al sensor de Sentinel-2, μ_2 a PlanetScope y μ_3 al dron.

$$Ho: \mu_1 = \mu_2 \qquad Ha: \mu_1 \neq \mu_2$$

$$Ho: \mu_1 = \mu_3 \qquad Ha: \mu_1 \neq \mu_3$$

$$Ho: \mu_2 = \mu_3 \qquad Ha: \mu_2 \neq \mu_3$$

La Tabla 4.7 presenta los valores para la Z crítica de los IV obtenidos con los datos estadísticos correspondientes al polígono M1, utilizados para comparar los tres sensores. Se observa que todas las pruebas de media mostraron diferencias estadísticamente significativas. Esto se atribuye a la cantidad de píxeles procesados por cada sensor, siendo el dron el que maneja una cantidad significativamente mayor en comparación con los otros dos sensores. Esta mayor cantidad de píxeles contribuye a una disminución en la desviación estándar, lo que resulta en un valor Z calculado considerablemente alto. Como consecuencia, estos valores caen dentro de la zona de significancia.

En el Anexo 8.3 podemos observar las tablas de la prueba de medias correspondientes a los tres polígonos restantes del cultivo de chile.

Tabla 4.7. Prueba de medias entre los sensores para el V2 con el polígono M1.

	M1			
IV	**Sentinel-2 vs PlanetScope**	**Sentinel-2 vs Dron**	**PlanetScope vs Dron**	**Z crítica**
RVI	-59.756	-41.124	62.571	1.96
GVI	-69.491	-11.605	177.395	1.96
NDVI	-57.746	-40.505	69.837	1.96
IPVI	-57.746	-40.505	69.837	1.96
GNDVI	-66.348	-11.206	213.231	1.96
OSAVI	-114.095	-95.229	69.821	1.96
WDRVI	-59.403	-41.045	64.280	1.96
TNDVI	-57.054	-40.222	71.561	1.96

4.6.2 Análisis de varianza (ANOVA)

Se realizó un análisis ANOVA para cada IV, donde se tomó como valor dependiente la media (promedio) del mismo y como factores (A) especie de chile, (B) vuelo y (C) sensor. En la Tabla 4.8 se

muestra a manera de ejemplo la tabla ANOVA que se obtuvo para el índice NDVI, en el Anexo 8.4 se encuentran todas las tablas ANOVA restantes.

Tabla 4.8. Análisis ANOVA para el índice NDVI.

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	0.012787	3	0.00426233	0.6	**0.6197**
B: Vuelo	2.38318	7	0.340454	47.57	**0.0000**
C: Sensor	2.71517	2	1.35758	189.7	**0.0000**
Residual	0.56537	79	0.00715658		
Total (corregido)	5.06214	91			

Tabla 4.9. Resultado de los Valores P de los IV analizados

	Factores		
IV	**Especie de chile**	**Vuelo**	**Sensor**
RVI	0.0453	0.0000	0.0000
GVI	0.1085	0.0000	0.0000
NDVI	0.6197	0.0000	0.0000
IPVI	0.6197	0.0000	0.0000
GNDVI	0.6958	0.0000	0.0000
OSAVI	0.5968	0.0000	0.0000
WDRVI	0.1722	0.0000	0.0000
TNDVI	0.7057	0.0000	0.0000

Los resultados recopilados de las tablas ANOVA indican que existe diferencia estadísticamente significativa entre los valores de los diversos índices en el vuelo que se realizó y también en el tipo de sensor utilizado, ya que en todos los casos el valor $P < 0.05$.

Por otro lado, en el análisis de varianza para la especie de chile podemos observar que para la mayoría de los índices el valor P > 0.05, los índices mayores a este resultado son el GVI, NDVI, IPVI, GNDVI, OSAVI, WDRVI y TNDVI. En base a esto podemos decir que tenemos evidencia estadística suficiente para decir que la media de la especie de chile es igual es cualquier de los IV mencionados anteriormente.

4.6.2.1 RVI

La Figura 4.7 muestra el comportamiento individual para los sensores Sentinel-2, PlanetScope y Dron para el índice de vegetación RVI. En la figura podemos observar que en los primero dos vuelos del dron el índice RVI mostro un comportamiento similar al índice obtenido con las imágenes de satélite de Sentinel y PlanetScope. Sin embargo, a partir del tercer vuelo los valores para el índice del dron no mostraron una variación significativa, mientras que los valores de Sentinel y PlanetScope si mostraron diferencia significativa ya que se incrementaron notablemente.

En el Anexo 8.5 se encuentran las gráficas obtenidas para los índices GVI, NDVI, IPVI, WDRVI, TNDVI los cuales mostraron un comportamiento semejante a lo mencionado para este índice.

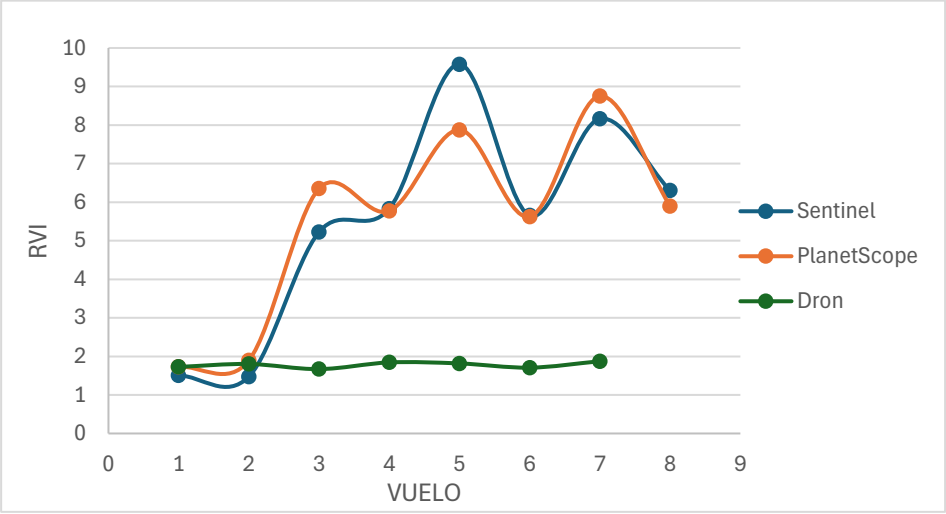

Figura 4.7. Gráfico del comportamiento individual para cada sensor en cada vuelo del RVI.

A partir del análisis estadístico de la prueba de rangos múltiple (LSD) podemos hacer un análisis más detallado sobre el comportamiento de este índice. La Figura 4.8a muestra que en promedio los

valores del RVI para Sentinel y PlanetScope fueron estadísticamente mayores que los del dron. Así mismo en la Figura 4.8b se observa que el comportamiento de los índices mostró una tendencia ascendente, siguiendo un patrón sigmoidal. En los primeros dos vuelos, se evidencia una fase de crecimiento de la biomasa del cultivo; a partir del vuelo 6, se alcanza el valor máximo de este índice de vegetación, que está directamente relacionado con la cantidad máxima de plantas en el cultivo y se mantiene durante los siguientes tres vuelos. Finalmente, en la Figura 4.8c, se presentan las diferentes especies dentro del cultivo, delimitadas en el área de estudio mediante polígonos. Se puede observar que M1, M2 y M3 no muestran diferencias significativas entre sí, mientras que M4 sí presenta diferencia significativa en comparación con al menos las dos primeras especies.

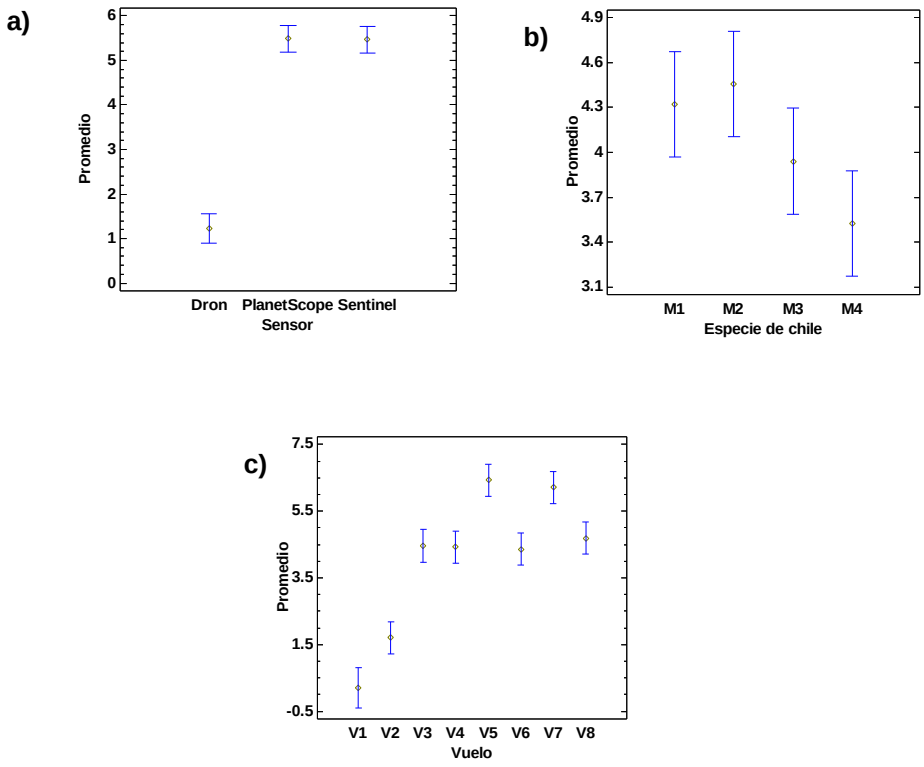

Figura 4.8. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice RVI.

El comportamiento descrito para la prueba LSD en la Figura 4.8 es el mismo para los índices GVI, NDVI, IPVI, GNDVI, WDRVI y TNDVI, mientras que el comportamiento de la Figura 4.8b es el mismo para dichos índices y también para el índice OSAVI.

4.6.2.2 GVI

La Figura 4.9c muestra la prueba LSD analizando la especie de chile para el índice GVI. Podemos ver que las especies dentro del cultivo no presentan evidencias estadísticas significativa, por lo que podemos decir que las especies son estadísticamente iguales entre sí. Este comportamiento de la Figura 4.9c también está presente en los índices NDVI, IPVI, GNDVI, OSAVI, WDRVI y TNDVI.

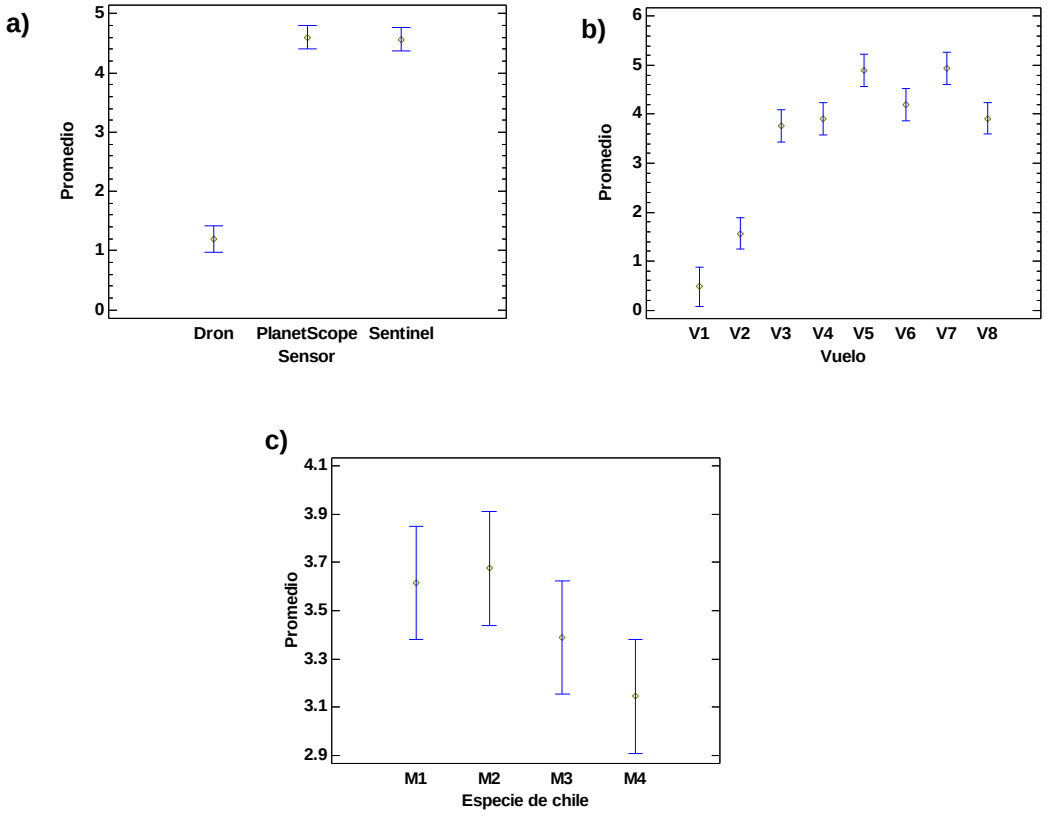

Figura 4.9. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice GVI.

4.6.2.3 GNDVI

En la Figura 4.10 se puede observar que los valores del índice GNDVI para los satélites Sentinel y PlanetScope presentan diferencia significativa contra los del dron, además el dron presente

variaciones significativas en sus vuelos como podemos notar los valores incrementan hasta el vuelo 3 pero a partir del vuelo 4 comienzan a descender respectivamente.

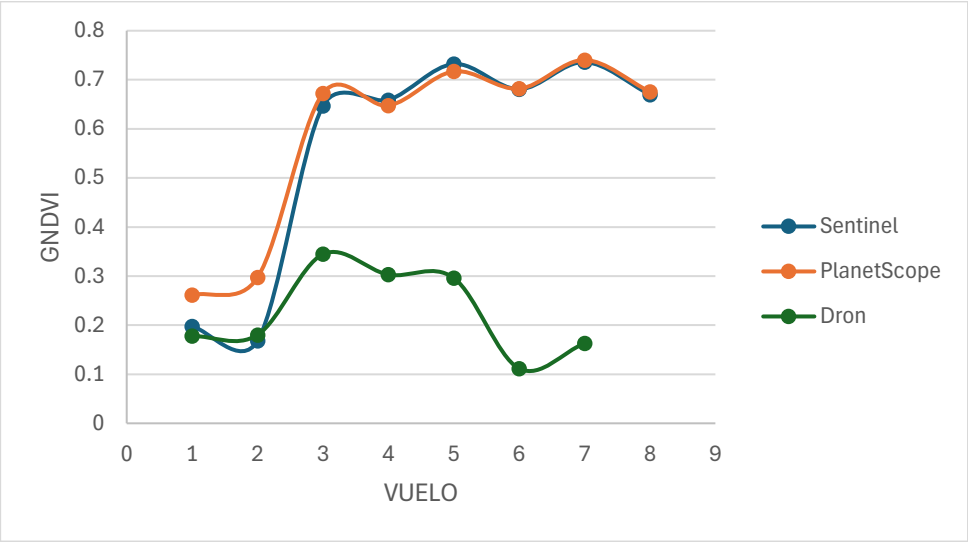

Figura 4.10. Gráfico del comportamiento individual para cada sensor en cada vuelo del GNDVI.

4.6.2.4 OSAVI

El índice OSAVI fue el único que evidenció diferencia estadísticamente significativa entre los tres sensores esto lo podemos ver más a detalle en la Figura 4.12a. Es por esto por lo que en el gráfico de la Figura 4.11 los valores de Sentinel y PlanetScope siguen presentando valores mayores que los del dron, pero adicionalmente presentan evidencia significativa entre sí.

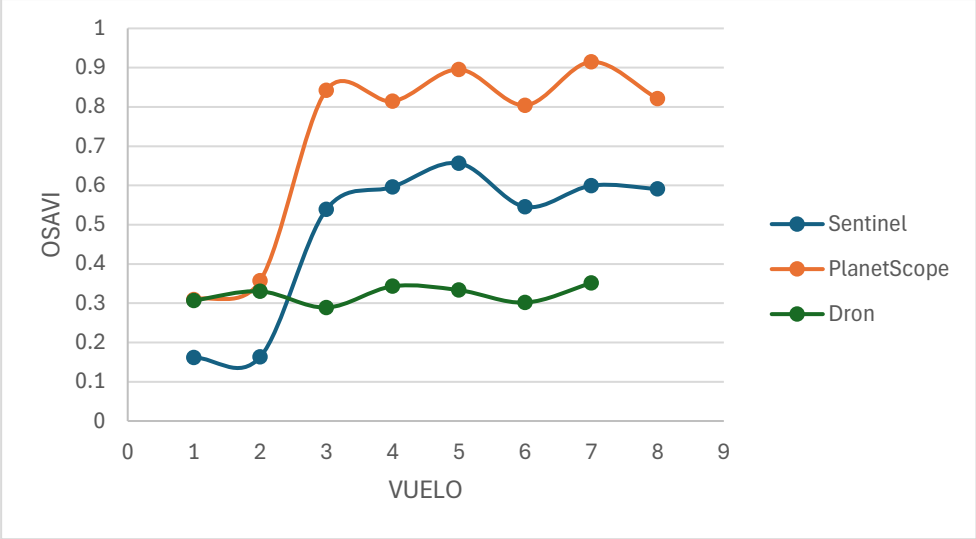

Figura 4.11. Gráfico del comportamiento individual para cada sensor en cada vuelo del OSAVI

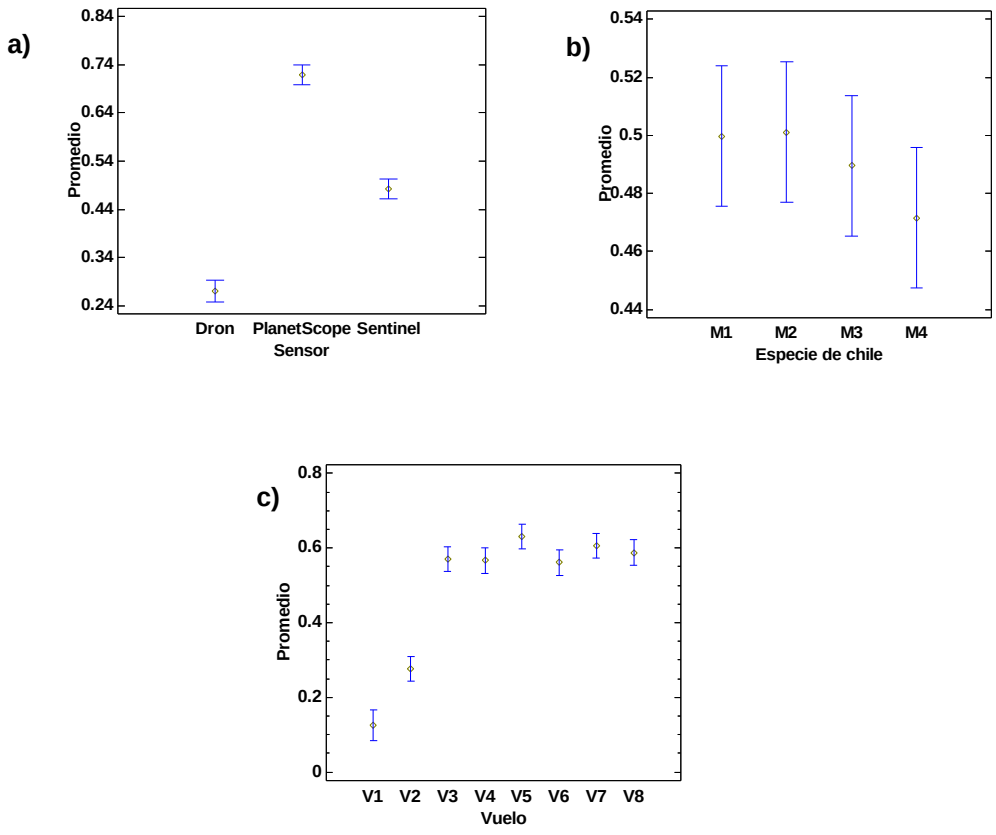

Figura 4.12. Resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para el índice OSAVI.

Las pruebas LSD para los índices NDVI, IPVI, GNDVI, WDRVI, TNDVI se encuentran en el Anexo 8.6.

5 CONCLUSIONES

En este proyecto, se ha llevado a cabo un meticuloso proceso de delimitación del área de cultivo de chile morrón, el cual ha sido fundamental para asegurar la calidad y relevancia de los datos obtenidos. A través de las actividades realizadas, se logró comparar estadísticamente los índices de vegetación de cada sensor, la implementación de un análisis de varianza fue fundamental para corroborar las diferencias estadísticas significativas.

Como era de esperarse los sensores presentaron evidencia estadísticamente significativa entre los factores estudiados para cada IV. Se puede afirmar que el comportamiento de Sentinel-2 y PlanetScope es semejante, ya que ambos realizan correcciones atmosféricas a sus imágenes debido a que la cámara de estos sensores atraviesa las diversas capas de la atmosfera para llegar al cultivo. Por otro lado, el dron puede ser llamado como la verdad terreno debido a que éste se encarga de sobrevolar el área a 40 metros aproximadamente de este modo las imágenes capturadas no presentan los factores ruido que influyen en las imágenes de los otros sensores, lo que hace que los datos del dron sean más precisos.

Por otro lado, las pruebas de diferencias de medias (LSD) proporcionaron una perspectiva más detallada para cada factor. El índice OSAVI fue el IV que presentó una diferencia significativa incluso entre el sensor de Sentinel-2 y PlanetScope, ya que este índice se adapta mejor a la variabilidad causada por los altos valores de fondo del suelo y a diferencia de otros índices, puede eliminar eficazmente la influencia del fondo del suelo.

Los resultados obtenidos no solo validan la efectividad del método de clasificación implementado, sino que también abren nuevas oportunidades para investigaciones futuras en el monitoreo y análisis de cultivos agrícolas. Las técnicas aplicadas pueden ser adaptadas y replicadas en otros contextos agrícolas, contribuyendo así al desarrollo sostenible y a la optimización del uso de recursos en la agricultura moderna.

6 COMPETENCIAS DESARROLLADAS

Logré adaptarme a un nuevo entorno que abarcaba tanto el análisis de datos como el uso de satélites y vehículos aéreos no tripulados. Además, tuve la oportunidad de trabajar con herramientas como QGIS y R Studio.

Reforcé mis conocimientos en ingeniería de calidad al crear una matriz de diseño desde cero, identificando factores que podrían afectar mi variable de respuesta. Realicé pruebas LSD y las interpreté, utilizando herramientas como Excel y Statgraphics.

Por último, mejoré mi habilidad para transmitir información de manera clara a través de la redacción y tuve la capacidad para ajustarme a cambios inesperados y responder de manera efectiva a nuevos desafíos.

7 FUENTES DE INFORMACIÓN

1. Aguilar Rivera, N. (2015). Percepción remota como herramienta de competitividad de la agricultura. *Revista Mexicana de Ciencias Agrícolas, 6*(2), 399-405. Recuperado el 20 de Octubre de 2024, de Revista Mexicana de Ciencias Agrícolas: https://www.scielo.org.mx/pdf/remexca/v6n2/v6n2a14.pdf

2. Aguirre Hernández, E., & Muños Ocotero, V. (2015). *El CHILE como alimento.* Obtenido de https://amc.edu.mx/revistaciencia/images/revista/66_3/PDF/Chile.pdf

3. Arreguín Jiménez, J. G. (2019). *Desarrollo tecnológico en agricultura de precisión: Perspectivas para México.* Obtenido de https://tesis.ipn.mx/bitstream/handle/123456789/27802/2019_Jos%C3%A9%20Guadalupe%20Arregu%C3%ADn%20Jim%C3%A9nez.pdf?sequence=1

4. Ayala Garay, A. V., Schwentesius Rindermann, R., & Carrera Chávez, B. (2012). Hortalizas en México: competitividad frente a EE.UU. y oportunidades de desarrollo. *Journal of Globalization, Competitiveness & Governability / Revista de Globalización, Competitividad y Gobernabilidad / Revista de Globalização, Competitividade e Governabilidade, 6*(3), 70-78. Obtenido de https://www.redalyc.org/pdf/5118/511851335003.pdf

5. Bajo, R. A., Ríos Flores, J. A., & Zazueta, D. (2021). *III. Pertinencia y funciones de las instituciones de educaciónsuperior pública de Sinaloa en la economía 4.0. El caso del sector agrícola.* Obtenido de Actividades del conocimiento y su desempeño en la competitividad de Sinaloa.

6. Balbontín, C., Odi, M., Poblete, R., Garrido, J., Campos, I., & Calera, A. (2016). *USO DE HERRAMIENTAS DE TELEDETECCIÓN Y SIG PARA EL MANEJO DEL RIEGO EN LOS CULTIVOS.* Obtenido de https://bibliotecadigital.ciren.cl/items/27a4abaa-7c2b-4ce4-abc8-773f3f98b751

7. Botana, M. I., & Fernández, S. E. (2019). *Teledetección como experiencia de aprendizaje : Una mirada desde Geografía Física I, Geografía de los Espacios Marítimos y Cartografía.* Obtenido de Actas. Ensenada: Universidad Nacional de La Plata. Facultad de Humanidades y Ciencias de la Educación, 2019.: https://www.memoria.fahce.unlp.edu.ar/trab_eventos/ev.13501/ev.13501.pdf

8. Callejas Ramos, A. I. (2016). *Algoritmos de reconstrucción de imágenes de escala de grises mediante GPU.* Obtenido de https://tesis.ipn.mx/bitstream/handle/123456789/23947/T1854.pdf?sequence=1&isAllowed=y

9. Cao, Y., Li, G. L., Luo, Y. K., Pan, Q., & Zhang, S. Y. (2020). Monitoring of sugar beet growth indicators using wide-dynamic-range vegetation index (WDRVI) derived from UAV multispectral images. *Computers and Electronics in Agriculture, 171*. Obtenido de https://doi.org/10.1016/j.compag.2020.105331

10. Cayado Fernández, A. (2014). *Espectro electromagnético y eficacia de los filtros ópticos en patología oculares.* Obtenido de http://uvadoc.uva.es/handle/10324/7032

11. CentroGeo. (2024). *Percepción Remota*. Obtenido de Centro de Investigación en Ciencias de Infromación Geoespacial: https://www.centrogeo.org.mx/agendas-de-investigacion/percepcion-remota

12. Chávez Martínez, O. (Octubre de 2022). *Estimación de índices espectrales de vegetación en cultivos de tomate cherri (Solanum lycopersicum var. cerasiforme) en las diferentes etapas de crecimiento de la planta utilizando imágenes multiespectrales a partir de VANTs".* Obtenido de http://repositorio.uas.edu.mx/jspui/handle/DGB_UAS/355

13. CODESIN. (2023). *Agricultura en Sinaloa al 2022.* Obtenido de SINALOA EN NÚMEROS: https://sinaloaennumeros.codesin.mx/wp-content/uploads/2023/06/Reporte-24-del-2023-de-Agricultura-en-sinaloa-2022.pdf

14. CODESIN. (2024). *Agricultura en Sinaloa al año 2023*. Obtenido de SINALOA EN NÚMEROS: https://sinaloaennumeros.codesin.mx/agricultura-en-sinaloa-al-ano-2023/

15. Copernicus. (2024). *Misión 2*. Obtenido de Copernicus Europe´s eyes on Earth: https://sentiwiki.copernicus.eu/web/s2-mission#S2-Mission-MSI-Instrument

16. de Martí, S. (2018). *AGRICULTURA DE PRECISIÓN Y PROTECCIÓN DE CULTIVOS.* Obtenido de Revista De Ingeniería, 1(47), 10-19.: https://doi.org/10.16924/revinge.47.3

17. Di Leon, N. (2015). *Drones: nueva dimensión de la teledetección agroambiental y nuevo paradigma para la agricultura de precisión.* Obtenido de https://rephip.unr.edu.ar/server/api/core/bitstreams/0d00425f-05ea-489c-84a6-be4dbcdb7a3d/content

18. Escalante Torrado, J. O., Cáceres Jiménez, J. J., & Porras Díaz, H. (2016). Ortomosaicos y modelos digitales de elevación generados a partir de imágenes tomadas con sistemas UAV. *Revista Tecnura, 20*(50), 119-140. Obtenido de http://www.scielo.org.co/scielo.php?pid=s0123-921x2016000400009&script=sci_arttext

19. ESERO Spain. (s.f.). *Longitud de Onda y Frecuencia*. Recuperado el 19 de Noviembre de 2024, de https://esero.es/practicas-en-abierto/decodifica-imagenes-iss/longitud_de_onda_y_frecuencia.html

20. Gama Moreno, L. A., Plazola Soltero, V. H., Murguia Vadillo, C. G., López Carrillo , E., & Martínez Hernández, C. (2022). Prototipo de Cámara Infrarroja para obtener el Índice NDVI en Agricultura de Precisión. *Programación matemática Y Software, 14*(1), 9-21. Obtenido de https://doi.org/10.30973/progmat/2022.14.1/2

21. Garcia Cardenas, D. A. (2018). *Dinámica de los índices de vegetación NDVI, GNDVI Y GVI en un cultivo de arroz a partir de imágenes aéreas multiespectrales tomadas por drones.* Obtenido de http://repositoriodspace.unipamplona.edu.co/jspui/handle/20.500.12744/4603

22. García Ferrer, A. (2013). Potencialidad y nuevas orientaciones en el uso de la teledetección en agricultura y selvicultura. *Ambienta 105*, 6-16.

23. García Gutiérrez, C., & Rodríguez Meza, G. D. (2012). *PROBLEMÁTICA Y RIESGO AMBIENTAL POR EL USO DE PLAGUICIDAS EN SINALOA.* Obtenido de Ra Ximhai, 8(3), 1-10.: https://www.uaim.edu.mx/webraximhai/Ej-25barticulosPDF/1%20GARCIA-GUTIERREZ.pdf

24. García, E., & Flego, F. (2008). *Agricultura de Precisión.* Obtenido de Revista Ciencia y Tecnología: https://www.palermo.edu/ingenieria/downloads/pdfwebc&T8/8CyT12.pdf

25. García, E., & Lárez Velásquez, C. (2020). *Preparación y caracterización de membranas semipermeables basadas en quitosano.* doi:10.13140/RG.2.2.26061.31205

26. Ghazal, S., Munir, A., & Qureshi, W. S. (2024). Computer vision in smart agriculture and precision farming: Techniques and applications. *Artificial Intelligence in Agriculture, 13*, 64-83. Obtenido de https://doi.org/10.1016/j.aiia.2024.06.004

27. Gil, E. (2010). *SITUACIÓN ACTUAL Y POSIBILIDADES DE LA AGRICULTURA DE PRECISIÓN.* Obtenido de https://www.researchgate.net/profile/Emilio-Gil-2/publication/28275751_Situacion_actual_de_la_agricultura_de_precision/links/02e7e5331cd3c28644000000/Situacion-actual-de-la-agricultura-de-precision.pdf

28. Gómez Ortega, Á. R. (2018). *Algoritmo para la generación de ortomosaicos a partir de imágenes aéreas tomadas por drones en la agricultura.* Obtenido de REPOSITOR ACADEMICO de la Universidad de Chile: https://repositorio.uchile.cl/handle/2250/164015

29. González, A., Amarillo, G., Amarillo, M., & Sarmiento, F. (2016). Drones Aplicados a la Agricultura de Precisión. *Publicaciones e Investigación, 10*, 23-37. Obtenido de https://doi.org/10.22490/25394088.1585

30. Gunathilaka, M. D. (2021). Modelling the Behavior of DVI and IPVI Vegetation Indices Using Multi-Temporal Remotely Sensed Data. *International Journal of Environment, Engineering and Education, 3*(1), 9-16. Obtenido de https://doi.org/10.55151/ijeedu.v3i1.42

31. Gutiérrez Pulido, H., & de la Vara Salazar, R. (2008). *Análisis y diseño de experimientos* (Segunda ed.). México: McGRAW-HILL/INTERAMERICANA EDITORES, S.A. de C.V.

32. Guzmán Álvarez, J. A., González Zuñiga, M., Sandoval Fernandez, J. A., & Calvo Alvarado, J. C. (2022). Uso de sensores remotos en la agricultura: aplicaciones en el cultivo del banano. *Agronomía mesoamericana, 33*(3).

33. Harris, D. R., & Fuller, D. Q. (2014). *Agriculture: Definition and Overview.* Obtenido de https://discovery.ucl.ac.uk/id/eprint/1429869/1/Harris_Fuller_AAM.pdf

34. Hernández Sánchez, L., Ortiz Torres, G., Sorcia Vázquez, F. d., & Rumbo Morales, J. Y. (2023). Uso de Vehículos Aéreos no Tripulados para aplicaciones de Agricultura de Precisión. *Seminario de Ingenierías Entre Cuerpos Académicos*, 113-119. Obtenido de Seminario de Ingenierías Entre Cuerpos Académicos : https://www.researchgate.net/profile/Jesse-Rumbo-Morales/publication/369472205_SEXTO_SEMINARIO_DE_INGENIERIAS_ENTRE_CUERPOS_ACADEMICOS_SEGUNDA_EDICION/links/641c6d8966f8522c38caf60c/SEXTO-SEMINARIO-DE-INGENIERIAS-ENTRE-CUERPOS-ACADEMICOS-SEGUNDA-EDICION.p

35. Huerta García, R. E. (2022). *INTEGRACIÓN DE REDES NEURONALES CONVOLUCIONALES Y PERCEPCIÓN REMOTA EN LA MODELACIÓN DE LA CONECTIVIDAD Y ACCESIBILIDAD DE ÁREAS VERDES URBANAS.* Obtenido de http://eprints.uanl.mx/id/eprint/26655

36. INTA Copernicus Relay. (2017). *Sentinel-1, -2, -3*. Obtenido de Instituto Nacional de Técnica Aeroespacial: https://www.inta.es/INTA/gl/blogs/copernicus/BlogEntry_1507278650016

37. ISPA. (Enero de 2024). *Definición de agricultura de precisión*. Obtenido de International Society of Precision Agriculture: https://www.ispag.org/about/definition

38. Jin, X.-l., Diao, W.-y., Xiao, C.-h., Wang, F.-y., Chen, B., Wang, K.-r., & Li, S.-k. (2013). *Estimation of Wheat Agronomic Parameters using New Spectral Indices.* Obtenido de https://doi.org/10.1371/journal.pone.0072736

39. Khanal, S., Fulton, J. P., Shearer, S., Özkan, E., & Kansas , K. (2020). Remote Sensing in Agriculture—Accomplishments, Limitations, and Opportunities. *Remote Sensing, 12*(22). doi:https://doi.org/10.3390/rs12223783

40. Levin, R. I., & Rubin, D. S. (2004). *Estadística para administración y economía* (Séptima ed.). México: PEARSON EDUCACIÓN. doi:ISBN 970-26-0497-4

41. Luque Ordóñez. (2012). Espectro electromagnético y espectro radioeléctrico. *Manual informativo de ACTA*(62), 17-31. Obtenido de https://www.acta.es/medios/articulos/ciencias_y_tecnologia/062017.pdf

42. Mitsikostas, E. (2017). *Monitorización y optimización de tierras con drones y fotogrametría aérea para aplicaciones de precisión en agricultura.* Obtenido de Universitat Politècnica de València: http://hdl.handle.net/10251/86353

43. Montero Zapata, J. E. (2022). *Descripción del uso de cámaras multiespectrales en el diagnóstico de cultivo.* Obtenido de http://dspace.utb.edu.ec/handle/49000/11311

44. Muñoz Aguayo, P. (2013). *Apuntes de Teledetección: Índices de vegetación.* Obtenido de Centro de Información de Recursos Naturales: https://www.researchgate.net/publication/327558326

45. Norasma, C., Fadzilah, M., Roslin, N., Zanariah, Z., Tarmidi, Z., & Candra, F. (2019). Unmanned Aerial Vehicle Applications In Agriculture. *IOP Conference Series: Materials Science and Engineering*. doi:10.1088/1757-899X/506/1/012063

46. Ocampo, M., & Santa Catarina, C. (Abril de 2018). *Agricultura de precisión.* Obtenido de Oficina de Información Científica y Tecnológica para el congreso de la Union (INCyTU): https://foroconsultivo.org.mx/INCyTU/documentos/Completa/INCYTU_18-015.pdf

47. Ojeda Bustamante, W., González Sánchez, A., Mauricio Pérez, A., & Flores Velázquez, J. (2017). Aplicaciones de los vehículos aéreos no tripulados en la ingeniería hidroagrícola. *Tecnologías y Ciencias del Agua , 8*(4), 157-166. Obtenido de https://www.scielo.org.mx/scielo.php?pid=S2007-24222017000400157&script=sci_arttext

48. Parra González, V. M., & Montorio Llovería, R. (2016). *Estimación del rendimiento de trigo con imágenes UAV: aplicación en el contexto de la agricultura de precisión.* Obtenido de ZAGUAN: https://zaguan.unizar.es/record/58585/files/TAZ-TFM-2016-1178.pdf

49. Pineda Pastrana, O. (2011). *Análisis de cambio de uso de suelo mediante percepción remota en el municipio de Valle de Santiago.* Obtenido de CENTRO DE INVESTIGACIÓN EN GEOGRAFÍA Y GEOMÁTICA ING. JORGE L. TAMAYO, A.C. CentroGeo: http://centrogeo.repositorioinstitucional.mx/jspui/handle/1012/41

50. Planet. (2024). *PlanetScope Overview*. Obtenido de Planet Developer Center: https://developers.planet.com/docs/data/planetscope/

51. Prado Molina, J., & Prado Morales , J. (2022). *Modelo de ingeniería de carga útil de percepción remota para la obtención de índices de vegetación "NDVI" a bordo de un CubeSat.* Obtenido de https://www.researchgate.net/profile/Jorge-Prado-Morales/publication/372855314_Modelo_de_ingenieria_de_carga_util_de_percepcion_remota_para_la_obtencion_de_indices_de_vegetacion_NDVI_a_bordo_de/links/64cac5ab91fb036ba6bfb510/Modelo-de-ingenieria-de-carga-

52. Rea Sánchez, V., Maldonado Cevallos, C., & Villao Santos, F. (13 de Abril de 2015). Los Sistemas de Información para lograr un desarrollo competitivo en el sector agrícola. *Revista Ciencia Unemi, 8*(13), 122-123. Obtenido de https://www.redalyc.org/pdf/5826/582663827014.pdf

53. Rigoberto, G. F., Agustín, T. D., & Raúl, H. G. (2017). El uso de drones en ciencias de la tierra. Obtenido de http://reaxion.utleon.edu.mx/Art_El_uso_de_drones_en_ciencias_de_la_tierra.html

54. Ríos Hernández, R. (2021). La Agricultura de Precisión. Una necesidad actuales. *Revista Ingeniería Agrícola, 11*(1), 67-74. Obtenido de Revista Ingeniería Agrícola, 11(1), 67-74.: https://www.redalyc.org/articulo.oa?id=586269368010

55. Ríos Hernández, R. (2021). Uso de los Drones o Vehículos Aéreos no Tripulados en la Agricultura de Precisión. *Revista Ingeniería Agrícola, 11*(4), 75-84.

56. Rodrígues Medrano, M. A. (2020). *Estudio sobre los efectos de la radiación en el espectro electromagnético sobre la salud humana.* Obtenido de https://repositorio.unitec.edu/xmlui/handle/123456789/11964

57. Rodríguez Herrera, A. L., Torres Trejo, E., & Linares Fleites, G. (2014). *Índices de vegetación y Uso de Suelo en la Región Terrestre Prioritaria 105: Cuetzalan, México.* Obtenido de RIUAGRO: http://200.4.142.40:8080/handle/uagro/606

58. Rosales Soto, A., & Arechavala Vargas, R. (2020). Agricultura inteligente en México: Analítica de datos como herramienta de competitividad. *VinculaTégica EFAN, 6*(2), 1415-1427. Obtenido de https://doi.org/10.29105/vtga6.2-619

59. Sánchez Méndez, A. G., & Arguijo Hernández, S. P. (2018). Análisis de imágenes multiespectrales para la detección de cultivos y detección de plagas y enfermedades en la producción de café. *Research in Computing Science, 147*(7), 309-317. Obtenido de https://rcs.cic.ipn.mx/2018_147_7/Analisis%20de%20imagenes%20multiespectrales%20para%20la%20deteccion%20de%20cultivos%20y%20deteccion%20de%20plagas.pdf

60. Secretaría de Agricultura y Desarrollo Rural. (2023). *Hablemos de… la agricultura en México (Parte 1).* Obtenido de GOBIERNO DE MÉXICO: https://www.gob.mx/agricultura/articulos/hablemos-de-la-agricultura-en-mexico-parte-1

61. Secretaría de Agricultura y Desarrollo Rural;. (2022). *México, principal exportador mundial de pimientos frescos: Agricultura.* Obtenido de GOBIERNO DE MÉXICO:

https://www.gob.mx/agricultura/prensa/mexico-principal-exportador-mundial-de-pimientos-frescos-agricultura

62. Servicio de Información Agroalimentaria y Pesquera. (01 de Diciembre de 2016). *Gobierno de México*. Obtenido de Servicio de Información Agroalimentaria y Pesquera: https://www.gob.mx/siap/articulos/somos-noveno-productor-de-hortalizas-a-nivel-mundial#:~:text=Las%20cinco%20principales%20hortalizas%20por,de%209.1%20millones%20de%20toneladas.

63. Shanmugapriya, P., Rathika, S., Ramesh, T., & Janaki, P. (2019). Applications of Remote Sensing in Agriculture - A Review. *International Journal of Current Microbiology and Applied Sciences, 8*(1), 2270-2283. doi:https://doi.org/10.20546/ijcmas.2019.801.238

64. Sishodia, R. P., Ray, R. L., & Singh, S. K. (2022). Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing,, 12*(19), 1-31. Obtenido de https://doi.org/10.3390/rs12193136

65. Solymosi, K., Kövér, G., & Romvári , R. (2019). The Development of Vegetation Indices: a Short Overview. *ACTA AGRARIA KAPOSVÁRIENSIS, 23*(1), 75-90. Obtenido de https://doi.org/10.31914/aak.2264

66. Sosa González, R. (2012). *Sistemas de Información Geográfica para la Agricultura de Precisión.* Obtenido de https://repositorio.uci.cu/bitstream/ident/TD_05742_12/2/TD_05742_12.pdf

67. Takalloo, S. (2024). *WATER STRESS DETECTION IN POTATO CROPS USING MULTISPECTRAL IMAGING AND ADVANCED OBJECT DETECTION MODELS.* Obtenido de Politecnico di Torino, Corso di laurea magistrale in Data Science And Engineering: http://webthesis.biblio.polito.it/id/eprint/33116

68. Uttaruk, Y., & Laosuwan, T. (2017). CARBON SEQUESTRATION ASSESSMENT OF THE ORCHARDS USING SATELLITE DATA. *Journal of Ecological Engineering, 18*(1), 11-17. doi:10.12911/22998993/66257

69. Veneros, J., García, L., Morales, E., Gómez, V., Torres, M., & López Morales, F. (2020). Aplicación de sensores remotos para el análisis de cobertura vegetal y cuerpos de agua. *Idesia (Arica), 38*(4), 99-107. Obtenido de http://dx.doi.org/10.4067/S0718-34292020000400099

70. Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*(1). doi:https://doi.org/10.1155/2017/1353691

71. Zaragoza, M. I., & Bartolucci, G. (2008). La imagen digital: expresión artística y modalidades de producción a través de la utilización de herramientas tecnológicas. *Huellas*(6), 91-101. Obtenido de https://bdigital.uncu.edu.ar/2563

72. Zou, F., Li, H., & Hu, Q. (2020). Responses of vegetation greening and land surface temperature variations to global warming on the Qinghai-Tibetan Plateau, 2001–2016. *Ecological Indicators, 119*. Obtenido de https://doi.org/10.1016/j.ecolind.2020.106867

73. Zwinkels, J. (2015). Light, electromagnetic spectrum. *Encyclopedia of Color Science and Technology*, 1-8.

8 ANEXOS

8.1 Ortomosaicos para los V2, V3, V4, V5, V7 Y V8 del dron respectivamente.

Fecha: 05/11/23

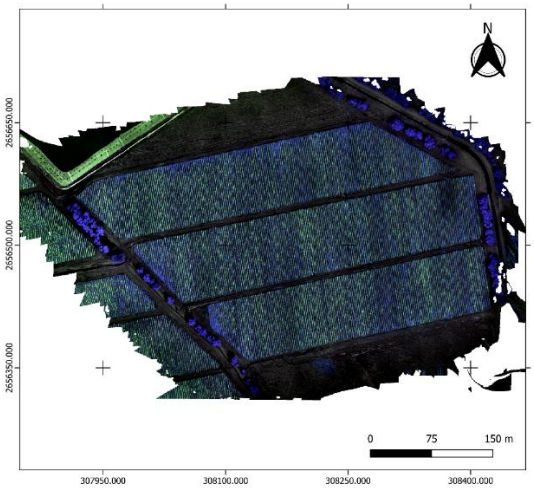

Fecha: 26/11/23

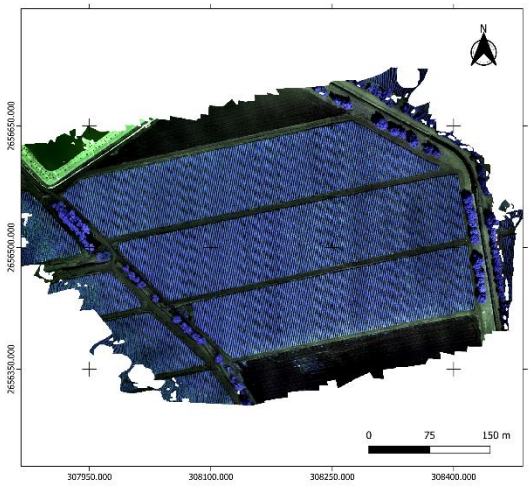

Fecha: 17/12/23

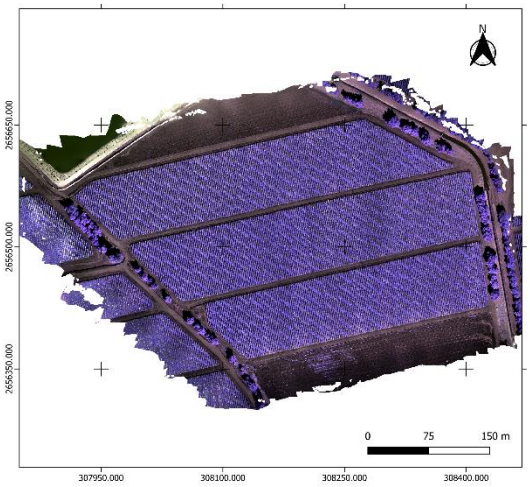

Fecha: 07/01/24

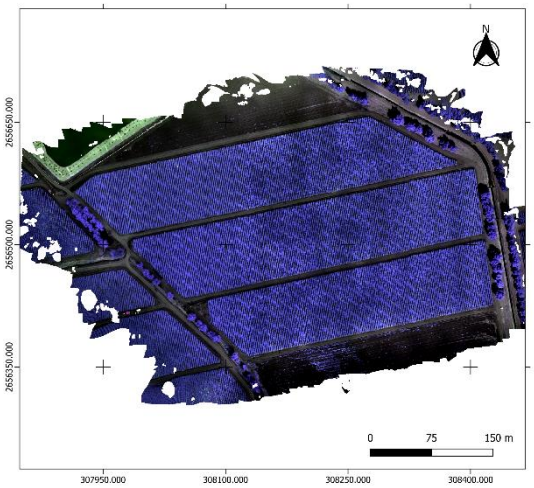

Fecha: 18/02/24

Fecha: 18/03/24

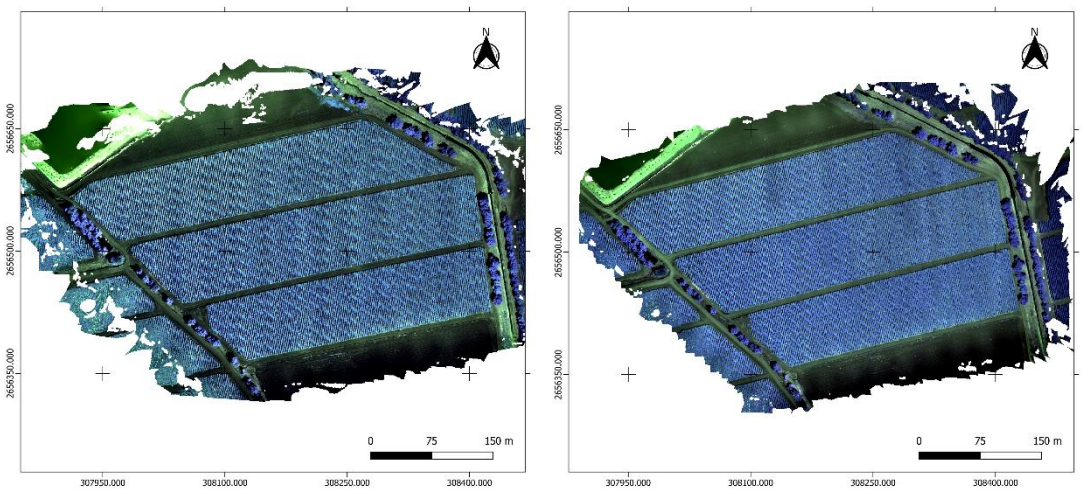

8.2 Ejemplo del código en R para el vuelo 7.

```
library(sp)

library(raster)

PLANT_M1<-raster("D:\\02_CLASIFICACION\\00_MASCARA_PLANTA\\MASC_M1_261123.tif")

PLANT_M2<-raster("D:\\02_CLASIFICACION\\00_MASCARA_PLANTA\\MASC_M2_261123.tif")

PLANT_M3<-raster("D:\\02_CLASIFICACION\\00_MASCARA_PLANTA\\MASC_M3_261123.tif")

PLANT_M4<-raster("D:\\02_CLASIFICACION\\00_MASCARA_PLANTA\\MASC_M4_261123.tif")

PLANT_M1[PLANT_M1==0]<-NA

PLANT_M2[PLANT_M2==0]<-NA

PLANT_M3[PLANT_M3==0]<-NA

PLANT_M4[PLANT_M4==0]<-NA



#POLIGONO M1
```

```
RVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\RVI_261123.tif")

RVI_M1_261123<-resample(RVI_M1_261123,PLANT_M1)

RVI_M1_261123_m<-(RVI_M1_261123*PLANT_M1)

prom<-(RVI_M1_261123.prom <- data.frame(RVI_M1_261123.mean=cellStats(RVI_M1_261123_m,
"mean")))

desv<-(RVI_M1_261123.desv <- data.frame(RVI_M1_261123.sd=cellStats(RVI_M1_261123_m, "sd")))


GVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GVI_261123.tif")

GVI_M1_261123<-resample(GVI_M1_261123,PLANT_M1)

GVI_M1_261123_m<-(GVI_M1_261123*PLANT_M1)

prom<-(GVI_M1_261123.prom<-data.frame(GVI_M1_261123.mean=cellStats(GVI_M1_261123_m,
"mean")))

desv<-(GVI_M1_261123.desv<-data.frame(GVI_M1_261123.sd=cellStats(GVI_M1_261123_m, "sd")))


NDVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\NDVI_261123.tif")

NDVI_M1_261123<-resample(NDVI_M1_261123,PLANT_M1)

NDVI_M1_261123_m<-(NDVI_M1_261123*PLANT_M1)

prom<-(NDVI_M1_261123.prom<-
data.frame(NDVI_M1_261123.mean=cellStats(NDVI_M1_261123_m, "mean")))

desv<-(NDVI_M1_261123.desv<-data.frame(NDVI_M1_261123.sd=cellStats(NDVI_M1_261123_m,
"sd")))
```

```
IPVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\IPVI_261123.tif")

IPVI_M1_261123<-resample(IPVI_M1_261123,PLANT_M1)

IPVI_M1_261123_m<-(IPVI_M1_261123*PLANT_M1)

prom<-(IPVI_M1_261123.prom<-data.frame(IPVI_M1_261123.mean=cellStats(IPVI_M1_261123_m,
"mean")))

desv<-(IPVI_M1_261123.desv<-data.frame(IPVI_M1_261123.sd=cellStats(IPVI_M1_261123_m,
"sd")))


GNDVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GNDVI_261123.tif")

GNDVI_M1_261123<-resample(GNDVI_M1_261123,PLANT_M1)

GNDVI_M1_261123_m<-(GNDVI_M1_261123*PLANT_M1)

prom<-(GNDVI_M1_261123.prom<-
data.frame(GNDVI_M1_261123.mean=cellStats(GNDVI_M1_261123_m, "mean")))

desv<-(GNDVI_M1_261123.desv<-
data.frame(GNDVI_M1_261123.sd=cellStats(GNDVI_M1_261123_m, "sd")))


OSAVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\OSAVI_261123.tif")

OSAVI_M1_261123<-resample(OSAVI_M1_261123,PLANT_M1)

OSAVI_M1_261123_m<-(OSAVI_M1_261123*PLANT_M1)
```

```
prom<-(OSAVI_M1_261123.prom<-
data.frame(OSAVI_M1_261123.mean=cellStats(OSAVI_M1_261123_m, "mean")))
desv<-(OSAVI_M1_261123.desv<-
data.frame(OSAVI_M1_261123.sd=cellStats(OSAVI_M1_261123_m, "sd")))

WDRVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\WDRVI_261123.tif")
WDRVI_M1_261123<-resample(WDRVI_M1_261123,PLANT_M1)
WDRVI_M1_261123_m<-(WDRVI_M1_261123*PLANT_M1)
prom<-(WDRVI_M1_261123.prom<-
data.frame(WDRVI_M1_261123.mean=cellStats(WDRVI_M1_261123_m, "mean")))
desv<-(WDRVI_M1_261123.desv<-
data.frame(WDRVI_M1_261123.sd=cellStats(WDRVI_M1_261123_m, "sd")))

TNDVI_M1_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\TNDVI_261123.tif")
TNDVI_M1_261123<-resample(TNDVI_M1_261123,PLANT_M1)
TNDVI_M1_261123_m<-(TNDVI_M1_261123*PLANT_M1)
prom<-(TNDVI_M1_261123.prom<-
data.frame(TNDVI_M1_261123.mean=cellStats(TNDVI_M1_261123_m, "mean")))
desv<-(TNDVI_M1_261123.desv<-
data.frame(TNDVI_M1_261123.sd=cellStats(TNDVI_M1_261123_m, "sd")))

#POLIGONO M2
```

```
RVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\RVI_261123.tif")

RVI_M2_261123<-resample(RVI_M2_261123,PLANT_M2)

RVI_M2_261123_m<-(RVI_M2_261123*PLANT_M2)

prom<-(RVI_M2_261123.prom <- data.frame(RVI_M2_261123.mean=cellStats(RVI_M2_261123_m,
"mean")))

desv<-(RVI_M2_261123.desv <- data.frame(RVI_M2_261123.sd=cellStats(RVI_M2_261123_m, "sd")))


GVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GVI_261123.tif")

GVI_M2_261123<-resample(GVI_M2_261123,PLANT_M2)

GVI_M2_261123_m<-(GVI_M2_261123*PLANT_M2)

prom<-(GVI_M2_261123.prom<-data.frame(GVI_M2_261123.mean=cellStats(GVI_M2_261123_m,
"mean")))

desv<-(GVI_M2_261123.desv<-data.frame(GVI_M2_261123.sd=cellStats(GVI_M2_261123_m, "sd")))


NDVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\NDVI_261123.tif")

NDVI_M2_261123<-resample(NDVI_M2_261123,PLANT_M2)

NDVI_M2_261123_m<-(NDVI_M2_261123*PLANT_M2)

prom<-(NDVI_M2_261123.prom<-
data.frame(NDVI_M2_261123.mean=cellStats(NDVI_M2_261123_m, "mean")))

desv<-(NDVI_M2_261123.desv<-data.frame(NDVI_M2_261123.sd=cellStats(NDVI_M2_261123_m,
"sd")))
```

```
IPVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\IPVI_261123.tif")

IPVI_M2_261123<-resample(IPVI_M2_261123,PLANT_M2)

IPVI_M2_261123_m<-(IPVI_M2_261123*PLANT_M2)

prom<-(IPVI_M2_261123.prom<-data.frame(IPVI_M2_261123.mean=cellStats(IPVI_M2_261123_m,
"mean")))

desv<-(IPVI_M2_261123.desv<-data.frame(IPVI_M2_261123.sd=cellStats(IPVI_M2_261123_m,
"sd")))


GNDVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GNDVI_261123.tif")

GNDVI_M2_261123<-resample(GNDVI_M2_261123,PLANT_M2)

GNDVI_M2_261123_m<-(GNDVI_M2_261123*PLANT_M2)

prom<-(GNDVI_M2_261123.prom<-
data.frame(GNDVI_M2_261123.mean=cellStats(GNDVI_M2_261123_m, "mean")))

desv<-(GNDVI_M2_261123.desv<-
data.frame(GNDVI_M2_261123.sd=cellStats(GNDVI_M2_261123_m, "sd")))


OSAVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\OSAVI_261123.tif")

OSAVI_M2_261123<-resample(OSAVI_M2_261123,PLANT_M2)

OSAVI_M2_261123_m<-(OSAVI_M2_261123*PLANT_M2)
```

```
prom<-(OSAVI_M2_261123.prom<-
data.frame(OSAVI_M2_261123.mean=cellStats(OSAVI_M2_261123_m, "mean")))

desv<-(OSAVI_M2_261123.desv<-
data.frame(OSAVI_M2_261123.sd=cellStats(OSAVI_M2_261123_m, "sd")))


WDRVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\WDRVI_261123.tif")

WDRVI_M2_261123<-resample(WDRVI_M2_261123,PLANT_M2)

WDRVI_M2_261123_m<-(WDRVI_M2_261123*PLANT_M2)

prom<-(WDRVI_M2_261123.prom<-
data.frame(WDRVI_M2_261123.mean=cellStats(WDRVI_M2_261123_m, "mean")))

desv<-(WDRVI_M2_261123.desv<-
data.frame(WDRVI_M2_261123.sd=cellStats(WDRVI_M2_261123_m, "sd")))


TNDVI_M2_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\TNDVI_261123.tif")

TNDVI_M2_261123<-resample(TNDVI_M2_261123,PLANT_M2)

TNDVI_M2_261123_m<-(TNDVI_M2_261123*PLANT_M2)

prom<-(TNDVI_M2_261123.prom<-
data.frame(TNDVI_M2_261123.mean=cellStats(TNDVI_M2_261123_m, "mean")))

desv<-(TNDVI_M2_261123.desv<-
data.frame(TNDVI_M2_261123.sd=cellStats(TNDVI_M2_261123_m, "sd")))


#POLIGONO M3
```

```
RVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\RVI_261123.tif")

RVI_M3_261123<-resample(RVI_M3_261123,PLANT_M3)

RVI_M3_261123_m<-(RVI_M3_261123*PLANT_M3)

prom<-(RVI_M3_261123.prom <- data.frame(RVI_M3_261123.mean=cellStats(RVI_M3_261123_m,
"mean")))

desv<-(RVI_M3_261123.desv <- data.frame(RVI_M3_261123.sd=cellStats(RVI_M3_261123_m, "sd")))


GVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GVI_261123.tif")

GVI_M3_261123<-resample(GVI_M3_261123,PLANT_M3)

GVI_M3_261123_m<-(GVI_M3_261123*PLANT_M3)

prom<-(GVI_M3_261123.prom<-data.frame(GVI_M3_261123.mean=cellStats(GVI_M3_261123_m,
"mean")))

desv<-(GVI_M3_261123.desv<-data.frame(GVI_M3_261123.sd=cellStats(GVI_M3_261123_m, "sd")))


NDVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\NDVI_261123.tif")

NDVI_M3_261123<-resample(NDVI_M3_261123,PLANT_M3)

NDVI_M3_261123_m<-(NDVI_M3_261123*PLANT_M3)

prom<-(NDVI_M3_261123.prom<-
data.frame(NDVI_M3_261123.mean=cellStats(NDVI_M3_261123_m, "mean")))

desv<-(NDVI_M3_261123.desv<-data.frame(NDVI_M3_261123.sd=cellStats(NDVI_M3_261123_m,
"sd")))
```

```
IPVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\IPVI_261123.tif")

IPVI_M3_261123<-resample(IPVI_M3_261123,PLANT_M3)

IPVI_M3_261123_m<-(IPVI_M3_261123*PLANT_M3)

prom<-(IPVI_M3_261123.prom<-data.frame(IPVI_M3_261123.mean=cellStats(IPVI_M3_261123_m,
"mean")))

desv<-(IPVI_M3_261123.desv<-data.frame(IPVI_M3_261123.sd=cellStats(IPVI_M3_261123_m,
"sd")))


GNDVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GNDVI_261123.tif")

GNDVI_M3_261123<-resample(GNDVI_M3_261123,PLANT_M3)

GNDVI_M3_261123_m<-(GNDVI_M3_261123*PLANT_M3)

prom<-(GNDVI_M3_261123.prom<-
data.frame(GNDVI_M3_261123.mean=cellStats(GNDVI_M3_261123_m, "mean")))

desv<-(GNDVI_M3_261123.desv<-
data.frame(GNDVI_M3_261123.sd=cellStats(GNDVI_M3_261123_m, "sd")))


OSAVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\OSAVI_261123.tif")

OSAVI_M3_261123<-resample(OSAVI_M3_261123,PLANT_M3)

OSAVI_M3_261123_m<-(OSAVI_M3_261123*PLANT_M3)
```

```
prom<-(OSAVI_M3_261123.prom<-
data.frame(OSAVI_M3_261123.mean=cellStats(OSAVI_M3_261123_m, "mean")))
desv<-(OSAVI_M3_261123.desv<-
data.frame(OSAVI_M3_261123.sd=cellStats(OSAVI_M3_261123_m, "sd")))

WDRVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\WDRVI_261123.tif")
WDRVI_M3_261123<-resample(WDRVI_M3_261123,PLANT_M3)
WDRVI_M3_261123_m<-(WDRVI_M3_261123*PLANT_M3)
prom<-(WDRVI_M3_261123.prom<-
data.frame(WDRVI_M3_261123.mean=cellStats(WDRVI_M3_261123_m, "mean")))
desv<-(WDRVI_M3_261123.desv<-
data.frame(WDRVI_M3_261123.sd=cellStats(WDRVI_M3_261123_m, "sd")))

TNDVI_M3_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\TNDVI_261123.tif")
TNDVI_M3_261123<-resample(TNDVI_M3_261123,PLANT_M3)
TNDVI_M3_261123_m<-(TNDVI_M3_261123*PLANT_M3)
prom<-(TNDVI_M3_261123.prom<-
data.frame(TNDVI_M3_261123.mean=cellStats(TNDVI_M3_261123_m, "mean")))
desv<-(TNDVI_M3_261123.desv<-
data.frame(TNDVI_M3_261123.sd=cellStats(TNDVI_M3_261123_m, "sd")))

#POLIGONO M4
```

```
RVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\RVI_261123.tif")

RVI_M4_261123<-resample(RVI_M4_261123,PLANT_M4)

RVI_M4_261123_m<-(RVI_M4_261123*PLANT_M4)

prom<-(RVI_M4_261123.prom <- data.frame(RVI_M4_261123.mean=cellStats(RVI_M4_261123_m,
"mean")))

desv<-(RVI_M4_261123.desv <- data.frame(RVI_M4_261123.sd=cellStats(RVI_M4_261123_m, "sd")))


GVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GVI_261123.tif")

GVI_M4_261123<-resample(GVI_M4_261123,PLANT_M4)

GVI_M4_261123_m<-(GVI_M4_261123*PLANT_M4)

prom<-(GVI_M4_261123.prom<-data.frame(GVI_M4_261123.mean=cellStats(GVI_M4_261123_m,
"mean")))

desv<-(GVI_M4_261123.desv<-data.frame(GVI_M4_261123.sd=cellStats(GVI_M4_261123_m, "sd")))


NDVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\NDVI_261123.tif")

NDVI_M4_261123<-resample(NDVI_M4_261123,PLANT_M4)

NDVI_M4_261123_m<-(NDVI_M4_261123*PLANT_M4)

prom<-(NDVI_M4_261123.prom<-
data.frame(NDVI_M4_261123.mean=cellStats(NDVI_M4_261123_m, "mean")))

desv<-(NDVI_M4_261123.desv<-data.frame(NDVI_M4_261123.sd=cellStats(NDVI_M4_261123_m,
"sd")))
```

```
IPVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\IPVI_261123.tif")

IPVI_M4_261123<-resample(IPVI_M4_261123,PLANT_M4)

IPVI_M4_261123_m<-(IPVI_M4_261123*PLANT_M4)

prom<-(IPVI_M4_261123.prom<-data.frame(IPVI_M4_261123.mean=cellStats(IPVI_M4_261123_m,
"mean")))

desv<-(IPVI_M4_261123.desv<-data.frame(IPVI_M4_261123.sd=cellStats(IPVI_M4_261123_m,
"sd")))


GNDVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\GNDVI_261123.tif")

GNDVI_M4_261123<-resample(GNDVI_M4_261123,PLANT_M4)

GNDVI_M4_261123_m<-(GNDVI_M4_261123*PLANT_M4)

prom<-(GNDVI_M4_261123.prom<-
data.frame(GNDVI_M4_261123.mean=cellStats(GNDVI_M4_261123_m, "mean")))

desv<-(GNDVI_M4_261123.desv<-
data.frame(GNDVI_M4_261123.sd=cellStats(GNDVI_M4_261123_m, "sd")))


OSAVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\OSAVI_261123.tif")

OSAVI_M4_261123<-resample(OSAVI_M4_261123,PLANT_M4)

OSAVI_M4_261123_m<-(OSAVI_M4_261123*PLANT_M4)
```

```
prom<-(OSAVI_M4_261123.prom<-
data.frame(OSAVI_M4_261123.mean=cellStats(OSAVI_M4_261123_m, "mean")))

desv<-(OSAVI_M4_261123.desv<-
data.frame(OSAVI_M4_261123.sd=cellStats(OSAVI_M4_261123_m, "sd")))


WDRVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\WDRVI_261123.tif")

WDRVI_M4_261123<-resample(WDRVI_M4_261123,PLANT_M4)

WDRVI_M4_261123_m<-(WDRVI_M4_261123*PLANT_M4)

prom<-(WDRVI_M4_261123.prom<-
data.frame(WDRVI_M4_261123.mean=cellStats(WDRVI_M4_261123_m, "mean")))

desv<-(WDRVI_M4_261123.desv<-
data.frame(WDRVI_M4_261123.sd=cellStats(WDRVI_M4_261123_m, "sd")))


TNDVI_M4_261123<-raster("D:\\01_INDICES_ORTOMOSAICOS\\TNDVI_261123.tif")

TNDVI_M4_261123<-resample(TNDVI_M4_261123,PLANT_M4)

TNDVI_M4_261123_m<-(TNDVI_M4_261123*PLANT_M4)

prom<-(TNDVI_M4_261123.prom<-
data.frame(TNDVI_M4_261123.mean=cellStats(TNDVI_M4_261123_m, "mean")))

desv<-(TNDVI_M4_261123.desv<-
data.frame(TNDVI_M4_261123.sd=cellStats(TNDVI_M4_261123_m, "sd")))
```

8.3 Tablas de prueba de medias entre sensores para el V2 con polígono M2, M3, M4.

M2

IV	Sentinel-2 vs PlanetScope	Sentinel-2 vs Dron	PlanetScope vs Dron	Z crítica
RVI	-79.891	-64.585	51.435	1.96
GVI	-89.378	-17.029	176.655	1.96
NDVI	-76.875	-61.766	57.431	1.96
IPVI	-76.875	-61.766	57.431	1.96
GNDVI	-85.430	-15.757	214.031	1.96
OSAVI	-142.506	-130.439	57.413	1.96
WDRVI	-79.448	-64.065	52.857	1.96
TNDVI	-75.674	-60.793	58.891	1.96

M3

IV	Sentinel-2 vs PlanetScope	Sentinel-2 vs Dron	PlanetScope vs Dron	Z crítica
RVI	-86.324	-45.682	102.575	1.96
GVI	-87.519	5.168	194.595	1.96
NDVI	-77.814	-41.947	112.878	1.96
IPVI	-77.814	-41.947	112.878	1.96
GNDVI	-78.956	7.202	238.576	1.96
OSAVI	-144.114	-105.388	112.864	1.96
WDRVI	-84.454	-44.817	104.920	1.96
TNDVI	-75.593	-41.004	115.427	1.96

M4

IV	Sentinel-2 vs PlanetScope	Sentinel-2 vs Dron	PlanetScope vs Dron	Z crítica
RVI	-104.822	-64.982	101.804	1.96
GVI	-121.799	-8.888	236.657	1.96
NDVI	-97.748	-61.365	113.987	1.96
IPVI	-97.748	-61.365	113.987	1.96

GNDVI	-111.106	-7.117	291.213	1.96
OSAVI	-177.846	-141.610	113.968	1.96
WDRVI	-103.443	-64.189	104.672	1.96
TNDVI	-95.632	-60.363	116.855	1.96

8.4 Tablas ANOVA para los índices RVI, GVI, IPVI, GNDVI, OSAVI, WDRVI y TNDVI respectivamente.

RVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	12.0639	3	4.0213	2.8	0.0453
B: Vuelo	309.816	7	44.2594	30.82	0
C: Sensor	337.542	2	168.771	117.53	0
Residual	113.444	79	1.436		
Total (corregido)	702.121	91			

GVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	4.04071	3	1.3469	2.09	0.1085
B: Vuelo	172.374	7	24.6249	38.16	0
C: Sensor	214.076	2	107.038	165.89	0
Residual	50.9728	79	0.645225		
Total (corregido)	398.145	91			

IPVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	0.00319675	3	0.00106558	0.6	0.6197
B: Vuelo	0.595794	7	0.0851135	47.57	0
C: Sensor	0.678792	2	0.339396	189.7	0
Residual	0.141342	79	0.00178914		
Total (corregido)	1.26553	91			

GNDVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	0.0104615	3	0.00348717	0.48	0.6958
B: Vuelo	2.2154	7	0.316486	43.74	0
C: Sensor	2.96632	2	1.48316	204.99	0
Residual	0.57158	79	0.00723519		
Total (corregido)	5.17652	91			

OSAVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					

A: Especie de chile	0.0128604	3	0.00428681	0.63	0.5968
B: Vuelo	2.26075	7	0.322965	47.59	0
C: Sensor	2.94793	2	1.47396	217.17	0
Residual	0.53618	79	0.00678709		
Total (corregido)	5.2275	91			

WDRVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	0.0569752	3	0.0189917	1.71	0.1722
B: Vuelo	2.88638	7	0.412339	37.07	0
C: Sensor	3.41703	2	1.70851	153.62	0
Residual	0.878628	79	0.0111219		
Total (corregido)	6.50959	91			

TNDVI

Fuente de variación	Suma de Cuadrados	Grados de libertad	Cuadrado medio	F calculada	Valor-P
Efectos principales					
A: Especie de chile	0.00256917	3	0.000856391	0.47	0.7057
B: Vuelo	0.615228	7	0.0878897	47.99	0
C: Sensor	0.683803	2	0.341902	186.7	0
Residual	0.144669	79	0.00183126		
Total (corregido)	1.28903	91			

8.5 Gráfico de comportamiento individual para cada sensor en cada vuelo de los índices GVI, NDVI, IPVI, WDRVI y TNDVI respectivamente.

GVI

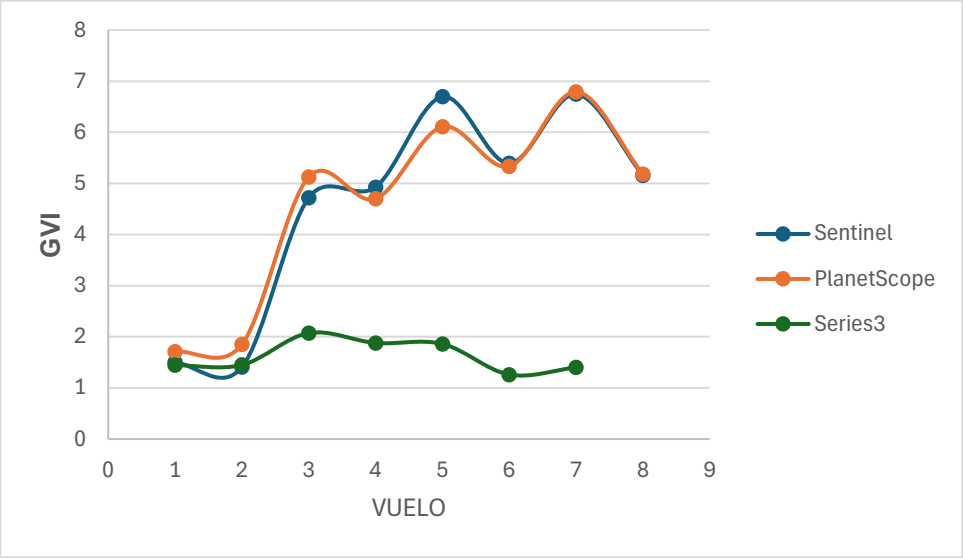

NDVI

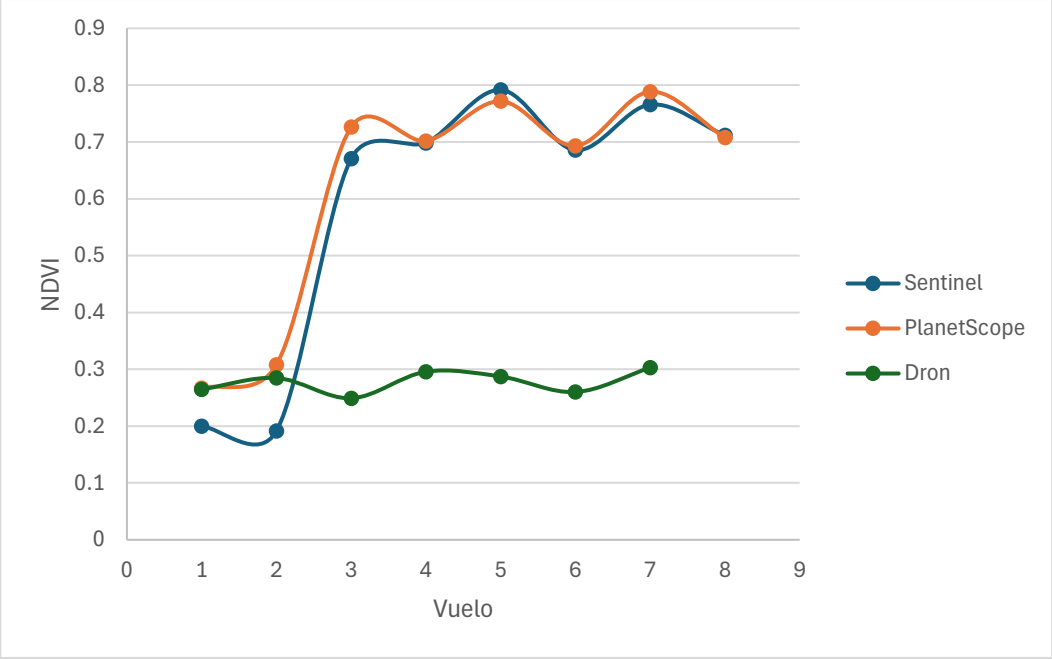

IPVI

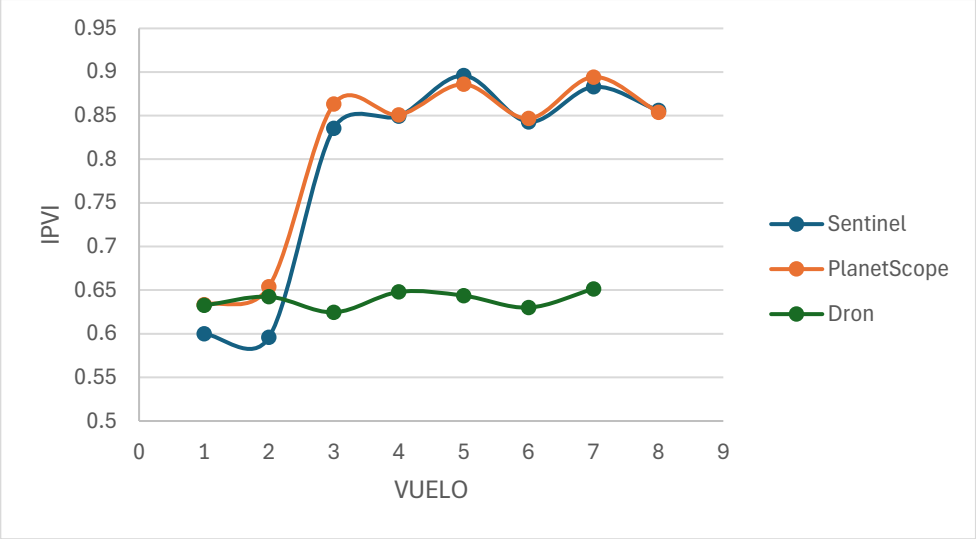
0.95
0.9
0.85
0.8
0.75
0.7
0.65
0.6
0.55
0.5
IPVI
0
1
2
3
4
5
6
7
8
9
VUELO
Sentinel
PlanetScope
Dron

WDRVI

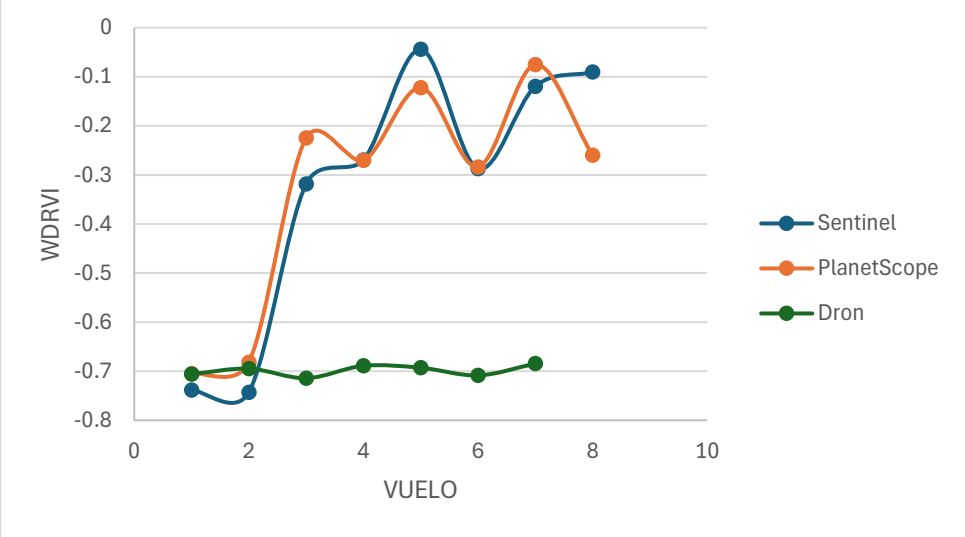
0
-0.1
-0.2
-0.3
-0.4
-0.5
-0.6
-0.7
-0.8
WDRVI
0
2
4
6
8
10
VUELO
Sentinel
PlanetScope
Dron

TNDVI

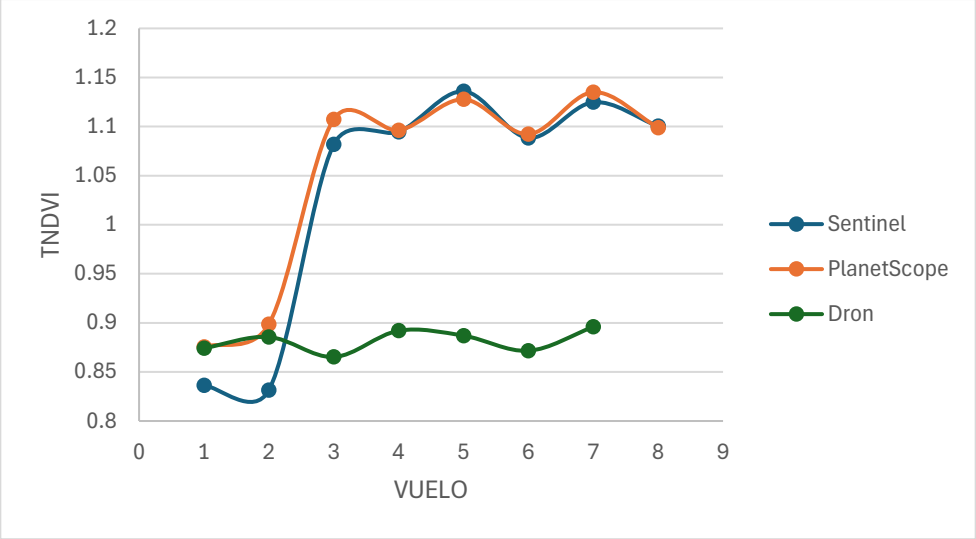

8.6 Gráficos de los resultados de la prueba LSD a) Sensor, b) vuelo, c) especie de chile para los índices NDVI, IPVI, GNDVI, WDRVI, TNDVI.

NDVI

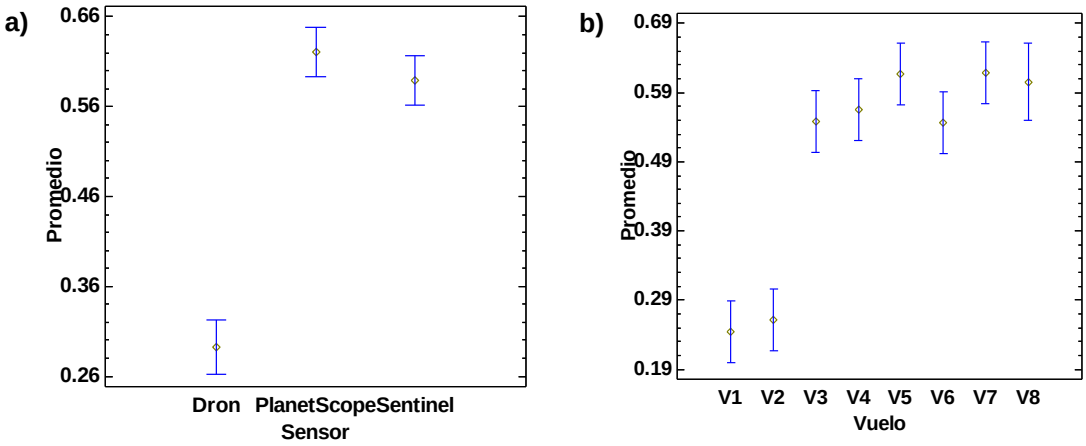

c)

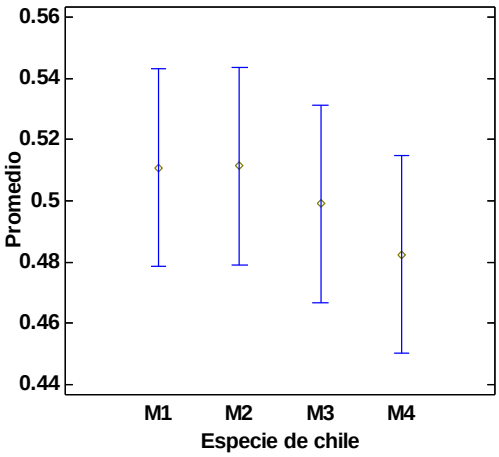

IPVI

a)

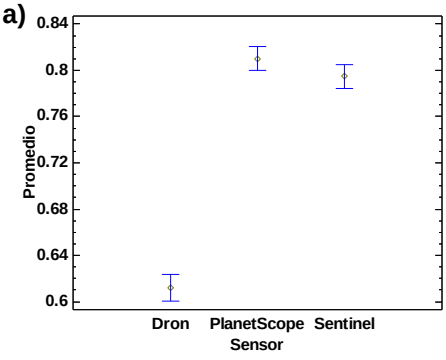

b)

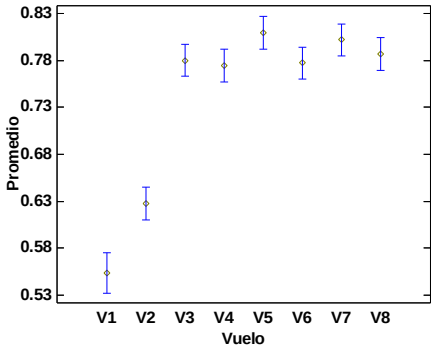

c)

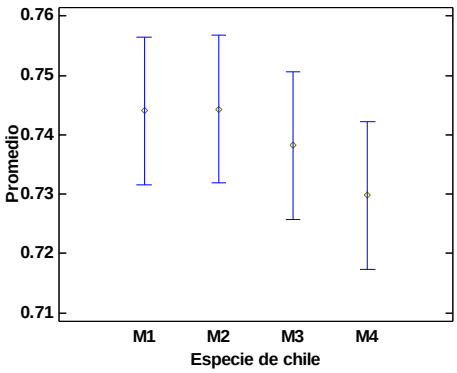

GNDVI

a)

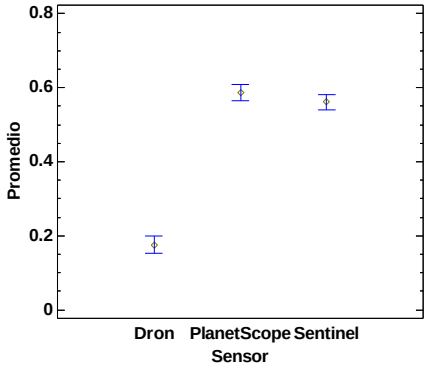
0.8
0.6
0.4
0.2
0
Promedio
Dron
PlanetScope
Sentinel
Sensor

b)

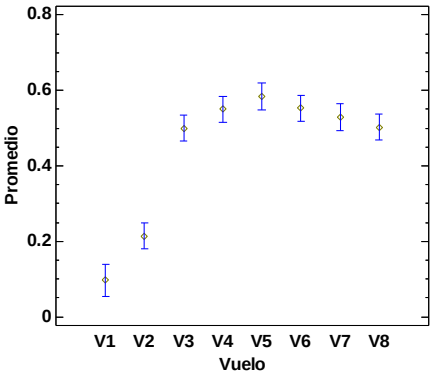
0.8
0.6
0.4
0.2
0
Promedio
V1
V2
V3
V4
V5
V6
V7
V8
Vuelo

c)

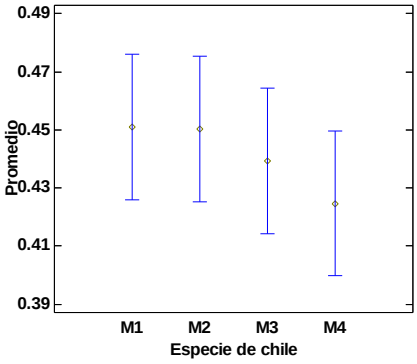
0.49
0.47
0.45
0.43
0.41
0.39
Promedio
M1
M2
M3
M4
Especie de chile

WDRVI

a)

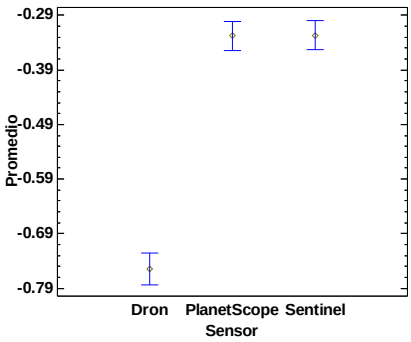
-0.29
-0.39
-0.49
-0.59
-0.69
-0.79
Promedio
Dron
PlanetScope
Sentinel
Sensor

b)

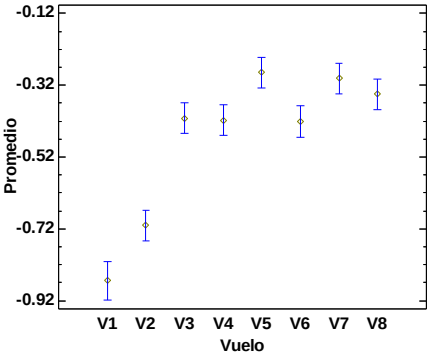
-0.12
-0.32
-0.52
-0.72
-0.92
Promedio
V1
V2
V3
V4
V5
V6
V7
V8
Vuelo

c)

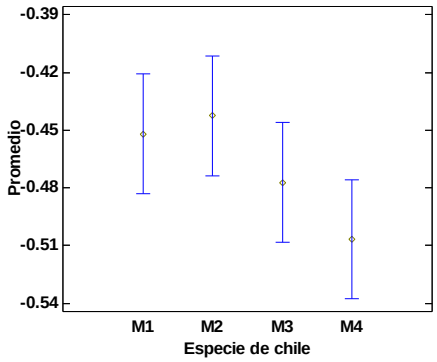
-0.39
-0.42
-0.45
-0.48
-0.51
-0.54
Promedio
M1
M2
M3
M4
Especie de chile

TNDVI

a)

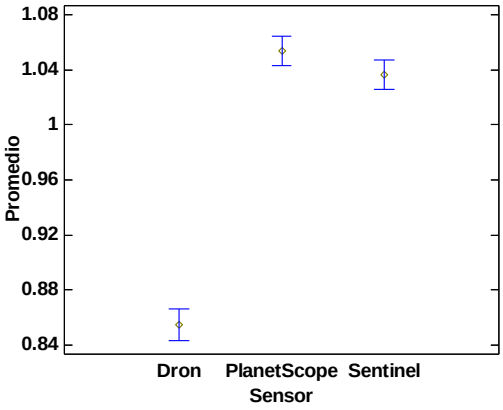
1.08
1.04
1
0.96
0.92
0.88
0.84
Promedio
Dron
PlanetScope
Sentinel
Sensor

b)

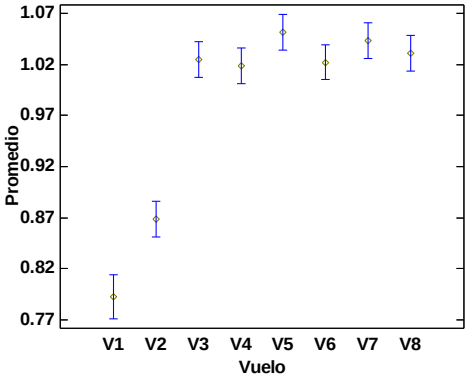
1.07
1.02
0.97
0.92
0.87
0.82
0.77
Promedio
V1
V2
V3
V4
V5
V6
V7
V8
Vuelo

c)

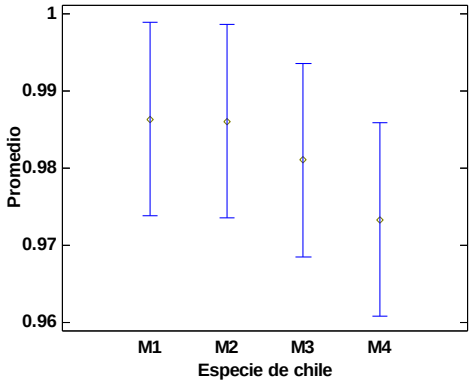
1
0.99
0.98
0.97
0.96
Promedio
M1
M2
M3
M4
Especie de chile

8.7 Carta de no inconveniente

Asunto: **Carta de no inconveniente.**

Ciudad de Culiacán, Sin., a 20 de diciembre de 2024.

MC. Edith Padilla Gasca.

Asesor interno del Instituto Tecnológico de Culiacán.

Por medio de la presente, me permito dirigirme a usted para manifestar el **NO TENER INCONVENIENTE** de que el Residente **IRMA VIRIDIANA VALENZUELA RUIZ**, con número de control **20171451**, realice los trámites necesarios para su de Titulación de **INGENIERO INDUSTRIAL**.

Lo anterior en virtud de que el Residente en mención ha cumplido de manera satisfactoria con las funciones encomendades en el proyecto “Optimización del cultivo de chile morrón (Capsicum Annumm) mediante su monitoreo utilizando índices espectrales”, durante el periodo comprendido del **Agosto-Diciembre 2024**, habiendo obtenido una calificación de residencias de **100**.

Sin más por el momento me despido quedando a sus órdenes para cualquier duda o aclaración.

Dr. Jesús Gabriel Rangel Peraza

Nombre y firma

Asesor externo de la Empresa

TNM140723GFA

RFC DE LA EMPRESA

TECNOLÓGICO NACIONAL DE MÉXICO / INSTITUTO TECNOLÓGICO DE CULIACÁN