

# Universidad Autónoma de Sinaloa

Facultad de Ciencias de la Tierra y el Espacio

Facultad de Informática Culiacán

Posgrado en Ciencias de la Información



**“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”**

## TESIS

Como requisito para obtener el grado de  
**Maestro en Ciencias de la Información**

**Osiris Chávez Martínez**

**Directores de tesis:**

**Dr. Sergio Alberto Monjardín Armenta**

**Dr. Jesús Gabriel Rangel Peraza**

**Culiacán, Sinaloa, México, octubre de 2022**



Dirección General de Bibliotecas  
Ciudad Universitaria  
Av. de las Américas y Blvd. Universitarios  
C. P. 80010 Culiacán, Sinaloa, México.  
Tel. (667) 713 78 32 y 712 50 57  
dgbuas@uas.edu.mx

## UAS-Dirección General de Bibliotecas

### Repositorio Institucional Buelna

#### Restricciones de uso

Todo el material contenido en la presente tesis está protegido por la Ley Federal de Derechos de Autor (LFDA) de los Estados Unidos Mexicanos (México).

Queda prohibido la reproducción parcial o total de esta tesis. El uso de imágenes, tablas, gráficas, texto y demás material que sea objeto de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente correctamente mencionando al o los autores del presente estudio empírico. Cualquier uso distinto, como el lucro, reproducción, edición o modificación sin autorización expresa de quienes gozan de la propiedad intelectual, será perseguido y sancionado por el Instituto Nacional de Derechos de Autor.

Esta obra está bajo una Licencia Creative Commons Atribución-No Comercial  
Compartir Igual, 4.0 Internacional



# Dedicatoria

## **A mi madre**

*Por su motivación en esta etapa de mi vida. Por sus consejos y apoyo. Gracias por ser un gran ejemplo que me ha ayudado a ser la persona que soy hoy en día. Y, sobre todo, por el gran cariño mostrado.*

## **A mi padre**

*Por siempre apoyarme desde que soy una niña. Que desde donde quiera que estés pudieras verme cumplir un logro más. Que en paz descanses papá.*

## **A Carlos**

*Por siempre apoyarme y ayudarme en cualquier situación. Me viste comenzar y terminar esta etapa de mi vida. Gracias por estar conmigo y espero poder seguir acompañándonos en cada logro mutuo.*

# **Agradecimientos**

## ***A la institución***

*Gracias a la institución y mis profesores por compartir sus conocimientos, y orientarme durante mi estancia en la Universidad Autónoma de Sinaloa.*

## ***A mis tutores***

*Gracias al Dr. Sergio Alberto Monjardin Armenta por su tiempo, apoyo en sus clases y elaboración de esta tesis. De igual forma, gracias al Dr. Jesús Gabriel Rangel Peraza por su ayuda y conocimientos desde la licenciatura, y elaboración de esta tesis.*

## ***A Tecnofersa***

*Gracias por darme la oportunidad y la confianza para realizar la experimentación de esta tesis con sus cultivos y el uso de sus productos.*

## ***A CONACYT***

*Gracias por darme la oportunidad y el apoyo financiero para poder realizar esta tesis.*

## Resumen

El presente trabajo evaluó una serie de índices de vegetación (RVI, GVI, NDVI, IPVI, NLI, GNDVI y OSAVI) en el monitoreo de un cultivo de tomate cherri utilizando un VANT y una cámara multiespectral con las bandas del rojo, verde e infrarrojo cercano. Se tomaron imágenes cada 2 semanas aproximadamente a dos parcelas divididas en tablas ( $T_1$  y  $T_2$ ); la  $T_1$  contaba con un tratamiento con agroquímicos utilizados con anterioridad; y la  $T_2$  contaba con un tratamiento con agroquímicos orgánicos.

Durante todo el monitoreo se obtuvieron un total de 7 vuelos, en los cuales se les aplicaron los índices anteriormente mencionados. Además, se calculó la media y desviación estándar, los cuales ayudaron a detectar el ruido provocado por las sombras y suelo en las tablas, por lo que se planteó el uso de una máscara la cual facilita la discriminación de estas zonas y solo analizar estadísticamente los pixeles que representan a la planta.

El análisis estadístico ANOVA nos mostró que los índices RVI, GVI, NDVI, IPVI, GNDVI y OSAVI tuvieron una diferencia significativa (Valor-P < 0.05) a lo largo del tiempo. El índice que no mostró un comportamiento similar fue el NLI. Este índice fue el que menos representa el comportamiento del crecimiento de la planta. Por otro lado, los índices no mostraron una diferencia significativa estadísticamente en el ANOVA entre las dos tablas. Sin embargo, en el 67% de los casos se reportan que los valores en el RVI, NDVI, IPVI y OSAVI fueron mayores en la  $T_2$  con respecto a la  $T_1$ . Siendo el IPVI, NDVI y OSAVI los más sensibles al mostrar una menor variación en los valores de pixeles.

Por lo que el RVI, GVI, NDVI, IPVI, GNDVI y OSAVI mostraron que pueden ser de gran ayuda para el monitoreo del cultivo en cielo abierto; como es el caso de la detección de zonas puntuales con afectaciones ya sea nutricional o enfermedad.

## Abstract

This research evaluated seven vegetation indices (RVI, GVI, NDVI, IPVI, NLI, GNDVI, and OSAVI) in a cherry tomato crop by using an unmanned aerial vehicle (UAV) and multispectral camera (RGN). Orthophotos were obtained every 2 weeks approximately from two tomatoes patches divided in tables ( $T_1$  and  $T_2$ );  $T_1$  had a treatment with historical agrochemicals; and  $T_2$  had a treatment with organic agrochemicals.

Seven photogrammetric flights were carried out to obtain the aforementioned vegetation indices. Since a high variation was observed, we proposed the use of a mask that facilitates the discrimination of noise areas (with the presence of soil and shadows). This discrimination process was carried out to take into account only the pixels that represent the plant.

The ANOVA statistical analysis demonstrated that the GVI, RVI, NDVI, IPVI, OSAVI and GNDVI indices showed a significant difference (P-value < 0.05) between dates. NLI did not show a significant difference, thus this is the index does not represent the growth of the tomato plant. On the other hand, ANOVA did not show a statistically significant difference between tables. However, 67% of the cases reported higher values of RVI, NDVI, IPVI, and OSAVI at  $T_2$  with respect to  $T_1$ . IPVI, NDVI, and OSAVI were the most sensitive indices, since they showed less variation. Therefore, RVI, GVI, NDVI, IPVI, GNDVI, and OSAVI showed that can be used for crop monitoring.

# Índice

Dedicatoria .....	II
Agradecimientos .....	III
Resumen .....	IV
Abstract .....	V
1. Introducción .....	1
1.1 Planteamiento del problema .....	3
1.2 Justificación .....	4
1.3 Hipótesis .....	5
1.4 Objetivo general .....	5
1.5 Objetivos específicos .....	5
2. Marco teórico .....	6
2.1 Índices de vegetación .....	6
2.2 Índices de vegetación aplicados en la agricultura .....	8
2.3 Agricultura de precisión .....	10
2.4 Fotogrametría .....	11
2.5 Percepción remota .....	13
2.6 Espectro electromagnético .....	14
2.7 Imágenes .....	17
2.7.1 Imagen digital .....	17
2.8 Resolución .....	18
2.8.1 Resolución espacial .....	18
2.8.2 Resolución espectral .....	18
2.8.3 Resolución temporal .....	19
2.8.4 Resolución radiométrica .....	20
2.9 Imágenes multiespectrales .....	21
2.10 Índices de vegetación .....	21
2.11 Características de la vegetación en el espectro óptico .....	22
2.12 Sistema de información geográfico .....	23
2.13 Tomate .....	24
3. Materiales y métodos .....	25
3.1 Área de estudio .....	25
3.2 Tipo y condiciones del cultivo .....	25
3.3 Metodología .....	27
3.4 Adquisición de las imágenes .....	28

3.4.1	Calibración de las imágenes .....	31
3.5	Generación de ortomosaicos.....	32
3.6	Algebra de bandas .....	34
4.	Resultados y discusiones .....	37
4.1	Imágenes espectrales .....	37
4.2	Generación de ortomosaicos.....	39
4.3	Generación y análisis de los IV .....	41
4.4	Análisis estadísticos de los índices espectrales.....	47
4.4.1	NLI .....	49
4.4.2	RVI.....	49
4.4.3	GVI.....	50
4.4.4	NDVI .....	51
4.4.5	IPVI .....	52
4.4.6	GNDVI .....	53
4.4.7	OSAVI.....	54
5.	Conclusiones .....	55
6.	Referencias.....	57
7.	Anexos.....	62

# Índice de figuras

<b>Figura 2.1.</b> Fotografía vertical tomada sobre un terreno completamente llano. El eje óptico, que corta el plano de la imagen en su centro $o$ , se encuentra con el suelo en ángulo recto en el punto principal $P$ . Fuente: (Sholarin & Awange, 2015) .....	13
<b>Figura 2.2.</b> Longitud de onda y frecuencia. ....	15
<b>Figura 2.3.</b> Espectro electromagnético. Fuente: (Frauenfelder, 2021). ....	16
<b>Figura 2.4.</b> a) imagen de ejemplo, b) porción de la imagen, c) Números digitales asociados con su posición. Fuente: (Wolf <i>et al.</i> , 2014). ....	17
<b>Figura 2.5.</b> Ejemplo de resolución espacial. Fuente: (Schowengerdt, 2007).....	18
<b>Figura 2.6.</b> Curvas de reflectancia espectral de la caolinita, la vegetación y el suelo. Fuente: (Villegas, 2008).....	19
<b>Figura 2.7.</b> Imagen de la presa Sanalona ubicada en Culiacán, Sinaloa, México, obtenida del satélite de Landsat 8 OLI/TIRS. La imagen a) fue captada en el mes de mayo del 2021, mientras que la imagen b) fue captada en septiembre del mismo año. ....	20
<b>Figura 2.8</b> Ejemplo de resolución radiometría. a) muestra la imagen original de 256 niveles de cuantificación, b) muestra la misma imagen con 8 niveles, c) con 4 niveles y d) con 2 niveles. Fuente: (Wolf <i>et al.</i> , 2014).....	20
<b>Figura 2.9.</b> Representación gráfica de una imagen RGB con una multiespectral. ....	21
<b>Figura 2.10.</b> Mapa de NDVI de un campo de maíz, derivado de imágenes aéreas de alta resolución espacial, que demuestra el poder de la resolución espacial fina para ayudar en la identificación de las causas de la variabilidad dentro de un campo de cultivo. Fuente: (van der Merwe <i>et al.</i> , 2020).....	22
<b>Figura 2.11.</b> Componentes de un SIG. ....	24
<b>Figura 3.1.</b> Ubicación del área de estudio. ....	25
<b>Figura 3.2.</b> a) Crecimiento de la planta de tomate en la $T1$ y b) crecimiento de la planta de tomate en la $T2$ en la fecha 18/12/2021. ....	26
<b>Figura 3.3.</b> Esquema metodológico utilizado.....	27
<b>Figura 3.4.</b> Phantom 4 Pro con cámara espectral anclada. Fuente: Fotografía propia. ....	28
<b>Figura 3.5.</b> Regiones de longitud de ondas de las bandas RGN. Fuente: (mapir, 2022) .....	29
<b>Figura 3.6.</b> Captura del vuelo desde la aplicación DJI GS Pro. ....	30
<b>Figura 3.7.</b> Objetivo terrestre utilizado.....	32
<b>Figura 3.8.</b> Flujo de trabajo en AgisoftMetashape.....	33

<b>Figura 3.9.</b> Área de estudio, delimitada en <i>T1</i> y <i>T2</i> .....	35
<b>Figura 3.10.</b> Máscara binaria de la <i>T1</i> y <i>T2</i> considerando solo el área que representa planta. Vuelo de la fecha 10/11/21.....	36
<b>Figura 4.1.</b> a.1) Imagen procesada, a.2) Imagen corregida radiométricamente, b) banda roja de la imagen, c) banda verde de la imagen y d) banda infrarroja cercana de la imagen.....	38
<b>Figura 4.2.</b> Ortomosaicos obtenidos en todos los vuelos realizados.....	39
<b>Figura 4.3.</b> Ortomosaico obtenido del vuelo 4 de la fecha 21/11/21.....	40
<b>Figura 4.4.</b> Resultados de los índices a) RVI, b) GVI, c) NDVI, d) IPVI, e) NLI, f) GNDVI y g) OSAVI del vuelo 4.....	42
<b>Figura 4.5.</b> Histogramas resultantes del índice GNDVI del V7 a) considerando toda la <i>T1</i> y b) considerando solo el área de la planta en la <i>T1</i> .....	44
<b>Figura 4.6.</b> Comparación del mismo índice GNDVI en diferentes vuelos a) V3 y b) V7. En donde se hace énfasis en zonas donde existió alguna perturbación de la planta y en fechas posteriores se corrigió. ....	48
<b>Figura 4.7.</b> Graficas del comportamiento en cada vuelo del NLI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	49
<b>Figura 4.8.</b> Graficas del comportamiento en cada vuelo del RVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	50
<b>Figura 4.9.</b> Graficas del comportamiento en cada vuelo del GVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	51
<b>Figura 4.10.</b> Graficas del comportamiento en cada vuelo del NDVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	52
<b>Figura 4.11.</b> Graficas del comportamiento en cada vuelo del IPVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	53
<b>Figura 4.12.</b> Graficas del comportamiento en cada vuelo del GNDVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a $P < 0.05$ , entre fechas.....	54

**Figura 4.13.** Graficas del comportamiento en cada vuelo del OSAVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas..... 55

## Índice de Tablas

<b>Tabla 3.1.</b> Composición del fertilizante orgánico-mineral suministrado (KeyPlex 350 OR). .....	26
<b>Tabla 3.2.</b> Características de la cámara mapir. ....	30
<b>Tabla 3.3.</b> Características de los vuelos realizados previamente de comenzar con los monitoreos. ....	31
<b>Tabla 3.4.</b> Ajustes de los parámetros en el flujo de trabajo de SfM. ....	33
<b>Tabla 3.5.</b> Índices aplicados en hortalizas según la literatura. ....	34
<b>Tabla 3.6.</b> Fórmulas para el ANOVA (multivariable).....	37
<b>Tabla 4.1.</b> Configuración de los parámetros de los vuelos realizados. ....	37
<b>Tabla 4.2.</b> Configuración de los parámetros de la cámara de los vuelos realizados. ....	38
<b>Tabla 4.3.</b> Bitácora de los vuelos realizados. ....	40
<b>Tabla 4.4.</b> Intervalos de tiempo entre vuelos. ....	41
<b>Tabla 4.4.</b> Medias y Desviaciones estándar obtenidos de los índices en los siete vuelos realizados. ....	42
<b>Tabla 4.5.</b> Medias y Desviaciones estándar de los índices utilizando la máscara binaria con la zona de interés (planta).....	45
<b>Tabla 4.6.</b> Análisis ANOVA del índice NDVI. ....	47
<b>Tabla 4.7.</b> Resultados de los Valores-P de los IV estudiado.....	47

## Lista de acrónimos

**AP:** Agricultura de precisión  
**GCP:** Ground Control Points  
**GNDVI:** Green Normalized Difference Vegetation Index  
**GNSS:** Global navigation satelital system  
**GSD:** ground sample distance  
**GVI:** Green Vegetation Index  
**INEGI:** Instituto Nacional de Estadística y Geografía  
**IPVI:** Infrared Percentage Vegetation Index  
**IV:** índices de Vegetación  
**N:** Nitrógeno  
**NDVI:** Normalized Difference Vegetation Index  
**NIR:** infrarroja cercana  
**NLI:** Non-Linear Index  
**ONU:** Organización de las Naciones Unidas  
**OSAVI:** Optimized Soil-Adjusted Vegetation Index  
**PR:** Percepción remota  
**PRI550:** Photochemical Reflectance Index Normalized  
**PRInorm:** Normalized Photochemical Reflectance Index  
**RDVI:** Renormalized Difference Vegetation Index  
**ReNDVI:** Red Edge Normalized Difference Vegetation Index  
**RVI:** Ratio Vegetation Index  
**SAVI:** Soil Adjusted Vegetation Index  
**SfM:** Structure from motion  
**SIG:** Sistemas de información geográfica  
**TCARI:** Transformed Chlorophyll Absorption in Reflectance Index  
**VANT:** Vehículos Aéreos No Tripulados  
**VIS:** Visible  
**WI/NDVI:** Normalized Water Index  
**WI:** Water Index

# 1. Introducción

Durante las últimas décadas la población ha crecido de manera exponencial; de acuerdo con la ONU, la población a nivel mundial en el 2017 era de 7.5 mil millones de personas, y se calcula que para el año 2030 serán alrededor de 8.5 mil millones de personas (United Nations & Department of Economic and Social Affairs, 2017). Esto conlleva a un nuevo desafío para la producción de alimentos y provoca el crecimiento en la demanda de uso de suelo para dicha actividad. En consecuencia, la superficie agrícola crece de manera acelerada, desorganizada y no sustentable, causando consigo problemas ambientales, sociales y económicos (Delgado *et al.*, 2019; Sishodia *et al.*, 2020).

Por tal razón, la comunidad científica ha enfocado esfuerzos en la AP, la cual se define como una tecnología de gestión basada en la información georreferenciada para el control de sistemas agrícolas, que permite el manejo de información espacial con detalle mediante la aplicación de procesos de monitoreo e integración de características de suelo, planta y clima (Alves Varella *et al.*, 2015). Esta tecnología permite el ahorro y aprovechamiento de los insumos, y ayuda a disminuir el impacto ambiental que trae consigo la agricultura, ya que esta práctica afecta al ambiente de manera negativa en el suelo, cuerpos de agua superficiales y mantos acuíferos.

Hoy en día la agricultura se encuentra en un estado crítico al consumir grandes cantidades de recursos que cada vez se encuentran más limitados. La agricultura es una actividad que afecta negativamente al medio ambiente; por ejemplo, casi dos terceras partes del agua utilizada por el hombre se destina a la agricultura además ser una de las fuentes de contaminación del agua por nitratos, fosfatos y plaguicidas (FAO, 2002). Por lo que se requiere que las actividades agrícolas sean cada vez más sostenibles, tanto social, económica y medioambiental, donde la AP representa una herramienta clave para tal fin. La AP es considerada una herramienta en temas de seguridad alimentaria, manejo de los recursos naturales y reducción en el impacto ambiental (Pantazi *et al.*, 2020).

En México, la implementación de AP es una práctica muy poco común, pero con el tiempo se ha ido incorporando con el fin de ahorrar y sacar el mejor provecho de los insumos necesarios para su producción. Algunas acciones que ayudan a fomentar su adaptación son la colaboración entre academia, industria, gobierno, productores; la actualización de la Ley de Desarrollo Rural Sustentable y del Reglamento de SAGARPA; la investigación, el desarrollo agrícola en México; la formación de recursos especializados; la promoción de programas piloto para cultivos estratégicos y su divulgación (Ocampo & Santa Catarina, 2018).

Sinaloa es reconocido al ser uno de los principales productores agrícolas a nivel nacional, encontrándose en el sexto lugar en producción, representando un 5% a nivel nacional, y en tercer lugar en productividad (CODESIN, 2021). Los principales cultivos producidos en Sinaloa que tuvieron un mayor valor en el mercado en el año 2019 fueron el chile verde (*Capsicum frutescens*), maíz (*Zea mays*), tomate verde (*Physalis ixocarpa*), mango (*Mangifera indica*) y papa (*Solanum tuberosum*), mientras en el 2020 fueron el

mango (*Mangifera indica*), tomate rojo (*Solanum lycopersicum*), frijol (*Phaseolus vulgaris*), sorgo grano (*Sorghum bicolor*) y papa (*Solanum tuberosum*). Con base en lo anterior, se puede argumentar que las hortalizas son unos de los principales cultivos en el estado de Sinaloa. Las hortalizas en este mismo año representaron una superficie de 64,093 hectáreas según CODESIN (2021).

A razón de las ideas anteriormente expuestas, la AP ha tomado gran importancia a nivel local y nacional. Actualmente con la ayuda de los VANTs, y sensores multiespectrales se pueden obtener con mayor precisión diferentes características físico-químicas de las plantas y desarrollar IV con base en información multiespectral. Estos índices se utilizan para detectar, monitorear y analizar las características de las plantas midiendo la reflectividad que tiene la estructura de la planta, siendo esta reflectividad captada por la cámara multiespectral montada a un VANTs (Mulla, 2013).

Uno de los componentes de la planta es la clorofila que ayuda a estudiar el estado de estrés en la planta, ya sea por escasas de agua, nutrientes, o por algún factor biótico o abiótico. La clorofila en las plantas juega un papel fundamental, ya que es utilizada como un bioindicador en este tipo de estudios. La medición de clorofila permite obtener información del estado de salud de la planta en tiempo real y a lo largo del tiempo a fin de describir el estado del cultivo e identificar posibles causas de su bajo rendimiento (Schlemmera *et al.*, 2013; Behmann *et al.*, 2014; Padilla *et al.*, 2018).

El presente estudio plantea fomentar en el área de la AP el uso de VANTs para el monitoreo de clorofila apoyado con IV en cultivos a cielo abierto con el fin de poder detectar de forma temprana problemáticas relacionadas con el estrés y ayudar en la toma de decisiones. El estudio se realizó en un cultivo de tomate cherri (*Solanum lycopersicum var. cerasiforme*) ubicado en Navolato, Sinaloa, México. Aportando así, resultados de índices multiespectrales aplicados en tomate, y posiblemente también ayude en el monitoreo de otro tipo de hortalizas.

## 1.1 Planteamiento del problema

Muchos de los problemas medioambientales relacionados con la agricultura seguirán impactando de manera grave. Una de las soluciones con respecto a esta problemática es la implementación de AP, ya que permite gestionar las actividades agrícolas con el objetivo de mejorar la productividad y el uso de los recursos. La AP ha demostrado un aumento en el rendimiento de los cultivos, la reducción de los insumos y la mitigación de los efectos ambientales adversos de las actividades agrícolas (Balafoutis *et al.*, 2017).

Por bastantes años los estudios relacionados a AP se llevaban a cabo mediante el uso de imágenes satelitales. Posteriormente, el desarrollo de los VANTs (también conocidos como drones) permitieron dar solución a las limitaciones que se tenían con los satélites, por ejemplo con la resolución espacial y temporal (Sishodia *et al.*, 2020). Hoy en día el uso de imágenes espectrales en combinaciones algebraicas para la obtención de IV han mejorado y ayudado a detectar el vigor y propiedades de la vegetación (dosel, radiación absorbida, contenido de clorofila) (Candiago *et al.*, 2015). Es así como los IV también permiten resolver problemáticas con respecto a estimar el comportamiento de la clorofila en plantas, como es el caso de la detección del estrés, el cual puede ser relacionado por el estado hídrico y de nutrientes.

Uno de los principales nutrientes que limita el desarrollo de la planta es el N; su incorrecta aplicación contribuye en la contaminación de cuerpos de agua superficiales y subterráneos (Padilla *et al.*, 2020). Por otro lado, el estrés hídrico en las plantas desencadena una serie de consecuencias físicas que afectan a la productividad de los cultivos. Además de tener una relación los IV con las condiciones climáticas de la zona de estudio (Cabrera-Bosquet *et al.*, 2011).

Tanto el estrés hídrico (Ihuoma & Madramootoo, 2019) como el estrés por falta de N (Gianquinto *et al.* 2011; Padilla *et al.* 2015; Elvanidi *et al.* 2018;) se han estudiado en hortalizas de forma separada, además de la relación entre el estrés hídrico y el contenido de N (Ihuoma & Madramootoo, 2020). Sin embargo, se hace énfasis en continuar investigaciones relacionadas ya que existe la necesidad de más indicadores de valores respecto al clima, el tipo de suelo y el tipo de cultivo para su aplicación (Sishodia, Ray, and Singh, 2020; Thenkabail, Smith, and De Pauw, 1995).

## 1.2 Justificación

Como se ha mencionado con anterioridad, la agricultura tiene un impacto tanto ambiental, social y económico (FAO, 2002; FAO, 2021). Tan solo en el año 2020, en Sinaloa se cultivaron 1 millón 067 mil 526 hectáreas (ha), las cuales produjeron 11 millones 803 mil 854 toneladas de alimentos con un valor de producción de 60 mil 873 millones de pesos (CODESIN, 2021), siendo uno de los estados con mayor aporte en este sector.

Además, se debe considerar que la agricultura representa la mayor proporción de uso de la tierra por el hombre (FAO, 2002). Al representar grandes áreas de uso de suelo, sumándole el inadecuado uso de agua, fertilizantes y plaguicidas, para contrarrestar esto, la aplicación de tecnologías permite optimizar insumos, reducir el impacto que conlleva la agricultura, y conservando y/o aumentando la producción de alimentos.

Los métodos utilizados para detectar alguna alteración o estrés en los cultivos agrícolas se apoyan en la supervisión en campo y corroborando en mediciones de laboratorio volviéndose bastante complejos. Sin embargo, las técnicas de laboratorio no permiten el análisis en tiempo real de los cultivos, y en ocasiones técnicas destructivas (Lu *et al.*, 2021). En este sentido, el uso de IV se vuelve una opción para la detección de problemáticas en cultivos agrícolas de forma no destructiva, además de poder tener en algunos casos información en tiempo real.

A fin de atender la problemática planteada, se propone establecer un IV que sea apropiado para su aplicación considerando las condiciones de la zona, tanto ambientales (temperatura, humedad, suelo), y como el tipo de cultivo. Para tal fin, se utilizó un vehículo aéreo no tripulado y una cámara espectral con las bandas del visible del verde, rojo y del Infrarrojo cercano. Con el desarrollo del presente proyecto se analizó el comportamiento espectral de un cultivo de tomate y con esa información poder plantearse en un futuro un adecuado uso de fertilizantes y del riego.

Por lo tanto, el presente estudio tiene por objetivo estimar índices de vegetación que permitan conocer el estado de la clorofila en un sistema de cultivo y el estrés de la planta, el cual se relaciona con un inadecuado manejo de los cultivos, con la ayuda de un vehículo aéreo no tripulado y una cámara espectral con las bandas del rojo, verde, e infrarrojo cercano. Estos índices fueron aplicados de forma local, sin embargo, el estudio pudiera tener un impacto económico, social y medioambiental en cualquier cultivo de tomate (*Solanum lycopersicum var. cerasiforme*) y sitio que cuente con características similares a la del área es estudio.

## 1.3 Hipótesis

El proceso digital de imágenes obtenidas con un vehículo aéreo no tripulado y una cámara multiespectral con las bandas del verde, rojo e infrarrojo cercano permitirá estimar diferentes tipos de índices espectrales de vegetación y determinar cuál de estos es el mejor índice a partir de un análisis en diferentes etapas del cultivo.

## 1.4 Objetivo general

- Evaluar los índices espectrales de vegetación (RVI, GVI, NDVI, IPVI, NLI, GNDVI, OSAVI) en el monitoreo del cultivo de tomate utilizando un vehículo aéreo no tripulado y una cámara multiespectral

## 1.5 Objetivos específicos

- Obtener imágenes aéreas espectrales con la ayuda de un vehículo aéreo no tripulado en un cultivo de tomate en las etapas de crecimiento de plántula, floración, fructificación.
- Obtener las ortofotografías y extraer los valores de las bandas espectrales en sus diferentes etapas de crecimiento.
- Generar y analizar los índices espectrales de vegetación.
- Realizar un análisis estadístico de los índices espectrales para determinar el mejor índice para el monitoreo del cultivo del tomate (*Solanum lycopersicum var. cerasiforme*).

## 2. Marco teórico

### 2.1 Antecedentes de los índices de vegetación

La comunidad científica a lo largo de los años ha tenido la necesidad de obtener información cartografiada sobre información del suelo, uso de la tierra, recursos naturales, conocimiento de las propiedades físicas, biológicas y químicas del suelo (Sishodia *et al.*, 2020). Por lo tanto, desde los años 60's, empezaron a surgir metodologías que facilitaban la gestión de la superficie terrestre, con el uso de la reflectancia espectral causada por los objetos, en este caso enfocados en la vegetación. Esta metodología es utilizada en la agricultura para gestionar y diseñar estrategias de riego, nutrientes, entre otros componentes esenciales para la agricultura.

En un inicio Birth & McVey (1968) con la ayuda de un espectrofotómetro, midieron las propiedades de reflectancia espectral del césped en crecimiento. A partir de estos datos se desarrolló una relación de reflectancia de las dos longitudes de onda:

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

Donde  $R_{NIR}$  es la región del infrarrojo cercano ( $0.745 \mu m$ ) y  $R_{RED}$  es la región del rojo ( $0.675 \mu m$ ).

Concluyendo que la hierba al estar en malas condiciones el índice de color será menor, y mientras la hoja muestre más clorofila el índice de color será mayor.

En 1974, Rouse *et al.*, (1974) realizaron un estudio para supervisar los sistemas de vegetación utilizando información del Landsat 1 (también conocido como ERTS-1). Utilizando los valores de radiación recolectados por las bandas espectrales 5 y 7, se calculó un parámetro de relación de bandas que se muestra correlacionado con áreas que presentan una biomasa de color verde (pastizales). El objetivo de este estudio era gestionar las áreas verdes que representaban zonas de pastizal, el cual es vulnerable a las condiciones climáticas, para su uso como alimento para la ganadería.

El estudio menciona que han encontrado otras combinaciones que podrían detectar la vegetación; sin embargo, para el estudio establecieron solo usar la banda 5 y 7. Establecieron un parámetro espectral abreviado BRP en inglés (Parámetro de relación de bandas) definido como la diferencia en el valor de radiancia de las bandas 5 y 7, dividido por la suma:

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (2.2)$$

Donde  $R_{NIR}$  es la región del infrarrojo cercano ( $0.8 - 1.1 \mu m$ ) y  $R_{RED}$  es la región del rojo ( $0.6 - 0.7 \mu m$ ). Utilizando valores desde -1 hasta 1.

El proceso de normalizado se utiliza para eliminar las diferencias estacionales del ángulo solar y minimizar el efecto de la atenuación atmosférica.

Por otro lado, Crippen, (1990) implementó un índice el cual es linealmente equivalente al NDVI, con la ventaja de que es computacionalmente más rápido y nunca obtendremos valores negativos (de 0 a 1). La ventaja de este índice con respecto al NDVI es identificada al momento de contar con un gran volumen de datos multitemporales:

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

Donde  $R_{NIR}$  es la región del infrarrojo cercano ( $0.8 - 1.1 \mu m$ ) y  $R_{RED}$  es la región del rojo ( $0.6 - 0.7 \mu m$ ).

Goel & Qin, (1994) desarrollaron dos nuevos índices no lineales siendo uno de ellos el NLI, este último es un índice simple, pero logra aprovechar la reflectancia de múltiples ángulos. Este índice se desarrolló utilizando la intuición en la física de la interacción entre la radiación óptica, el dosel de la vegetación y utilizando algunos resultados de modelos analíticos como el de Qin y Jupp en el año 1993. Este índice pretende minimizar los efectos de las perturbaciones como el ocasionado por el brillo del suelo:

$$NLI = \frac{R_{NIR}^2 - R_{RED}}{R_{NIR}^2 + R_{RED}} \quad (2.4)$$

Donde  $R_{NIR}$  es la región del infrarrojo cercano ( $0.70 - 0.9 \mu m$ ) y  $R_{RED}$  es la región del rojo ( $0.63 - 0.69 \mu m$ ).

Gitelson & Merzlyak, (1997) aportaron un nuevo índice el cual, con el uso de los canales verde y rojo (cerca de 700 nm), es posible aumentar la sensibilidad del NDVI para la detección del contenido de clorofila aproximadamente cinco veces más. Teniendo el objetivo de desarrollar un índice que predijera de forma precisa la clorofila de una forma no invasiva para cualquier especie de planta y en diferentes climas.

Este estudio demostró que el contenido de la clorofila tenía una fuerte relación entre la región del espectro  $R_{550}$  y  $R_{700}$ . Llegando a la conclusión que la reflectancia en el rango de 549 – 570 nm (verde) y alrededor de 690 - 710 nm también se pueden usar como términos sensibles en NDVI, en lugar del canal habitual centrado en 670 nm:

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

Utilizando valores desde -1 hasta 1. Es importante resaltar que este índice es más sensible a la clorofila en las vegetaciones de color verde amarillento o color verde oscuro.

Haboudane *et al.*, (2002) integró un índice de vegetación que minimiza los efectos del suelo sobre la reflectancia del dosel. El índice OSAVI pertenece a la familia del índice SAVI:

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

Donde  $R_{NIR}$  es la región del infrarrojo cercano ( $0.8 \mu m$ ) y  $R_{RED}$  es la región del rojo ( $0.67 \mu m$ ). Utilizando valores desde -1.16 hasta 1.16.

Sin embargo, los índices presentados son solo una pequeña parte de los índices de vegetación multispectrales que sido aplicados para la detección de vegetación y que pueden permitir conocer el estado fisiológico de la planta. Sin embargo, estos índices han sobresalido en los últimos años para la detección de estrés en la agricultura, principalmente en el caso de las hortalizas.

## 2.2 Índices de vegetación aplicados en la agricultura

Padilla *et al.*, (2015), realizó un estudio con el cultivo de tomate (*Solanum lycopersicum*) en invernadero en la temporada de primavera-verano. El tratamiento experimental consistió en suministrar cuatro tratamientos nutricionales con concentraciones distintas de N. Además, se utilizaron prácticas de manejo de cultivos locales; el cultivo se podaba periódicamente y se sostenía verticalmente con guías de hilo de nailon para mantener una estructura de dosel abierta. Se realizaron mediciones ópticas del contenido de clorofila de las hojas con un medidor de clorofila de mano (SPAD-502). Las mediciones fueron realizadas de forma individual, el SPAD mide un área de superficie foliar de  $6 mm^2$ . Las mediciones con este dispositivo comenzaron una semana después del inicio de los tratamientos experimentales y luego se repitieron semanalmente hasta el final de la cosecha. Para las medidas de la reflectancia seleccionaron filtros para medir la reflectancia a 550 nm (verde), 670 nm (rojo) y 760 nm (infrarrojo cercano, NIR).

Las diferencias en el contenido de N del cultivo en pie y las mediciones del sensor óptico entre los tratamientos de N a lo largo del tiempo se evaluaron mediante análisis de varianza de medidas repetidas (RM-ANOVA), utilizando el tiempo y el tratamiento con N como factores. También, por cada fecha de medición del sensor óptico (medición real o índice derivado), se realizó un análisis de regresión lineal para evaluar las relaciones entre la medición del sensor óptico y el contenido de N del cultivo. Se concluyó que los índices basados en la reflectancia en el rojo, el NDVI y el RVI, fueron los mejores predictores del estado del N del cultivo en términos de bondad de ajuste, precocidad y mantenimiento de relaciones en todo el cultivo. El GNDVI y el GVI, fueron buenos indicadores del estado de N del cultivo para la mayor parte del cultivo, pero con menor bondad de encajar en la última parte del cultivo.

Asimismo, Shaver *et al.*, (2017) realizó un estudio en maíz en donde en dos sitios dividieron las parcelas por cada tratamiento, este estudio permitió identificar que el ReNDVI es superior al NDVI para las determinaciones de N en etapas tardías del maíz.

En ese mismo año, Kyratzis *et al.*, (2017) realizó un estudio durante dos años en plantas de trigo, en el que hizo uso del NDVI y el GNDVI derivados de imágenes obtenidas con la ayuda de un VANT en un conjunto de variables de trigo cultivados bajo estrés relacionado con la escasez hídrica y el ambiente por calor. El diseño de experimentos utilizado fue de bloques al azar con cuatro repeticiones en el primer año, y en el

segundo año se realizaron cinco repeticiones. En este estudio recomendaron el uso de GNDVI y NDVI para predecir el rendimiento del trigo, destacando de estos el GNDVI el cual obtuvo una mejor eficiencia de discriminación y puede ser un mejor predictor del rendimiento.

Ranjan *et al.*, (2019) realizó un estudio con 8 cultivos de frijol pinto, realizando la adquisición de datos en las etapas de crecimiento temprana, media y tardía. Se empleó un generador de imágenes multiespectral de tipo semiconductor de óxido de metal complementario de cinco bandas (azul (465-485 nm), verde (550-570 nm), rojo (663-673 nm), borde rojo (RE, 712-722 nm) e infrarrojo cercano (NIR, 820-860 nm). Se realizó un análisis de componentes principales y pruebas de correlación de rango de Spearman para identificar el índice de vegetación clave y su correlación con el estrés abiótico en cada etapa de crecimiento. Este estudio demostró que el índice de NLI, el NLI modificado y IPVI fueron consistentes en la contabilización de la respuesta al estrés. Sin embargo, aclara que todos los índices tratados pueden funcionar para el monitoreo del estrés.

De manera similar Ihuoma & Madramootoo, (2019) realizaron un estudio en plantas de tomate (*Solanum lycopersicum L.*) cultivadas en invernadero. El experimento se organizó en un diseño completamente al azar con cinco niveles de tratamiento de agua de 100, 80, 60, 40 y 20% del agua disponible de la planta. Las aplicaciones de riego se basaron en el agua disponible de la planta y el contenido de humedad del suelo en cada maceta se midió continuamente con sensores de humedad. Con la ayuda de un espectrómetro de fibra óptica en miniatura, se midió la reflectancia del dosel, en donde se muestra una respuesta espectral al estrés hídrico, la cual fue más evidente en las etapas de floración y madurez temprana debido a que las plantas son más sensibles al estrés hídrico en estas etapas.

Estos mismos valores medidos de reflectancia foliar se utilizaron para el cálculo de los índices espectrales de vegetación. El análisis estadístico de los índices reveló que el  $PRI_{550}$ , WI, OSAVI, WI/NDVI se relacionaron significativamente con el estrés hídrico en las plantas de tomate, mientras que NDVI, RDVI y  $PRI_{norm}$  no mostraron diferencias significativas entre varios niveles de estrés hídrico.

Posteriormente, Ihuoma & Madramootoo, (2020) realizaron otro análisis en las plantas de tomate (*Solanum lycopersicum L.*) cultivadas en invernadero, en esta ocasión evaluando la sensibilidad de los índices de vegetación en los efectos combinados con el estrés hídrico y N. Los tratamientos consistieron en la aplicación de agua de riego en cantidades del 100, 70 y 30% de la reposición total de agua del suelo en la zona de las raíces hasta la capacidad del campo. Para inducir el estrés nitrogenado de leve a severo, se realizaron las aplicaciones de N al 100, 70 y 30% del requerimiento de nitrógeno del cultivo, correspondiendo a 54, 38 y 16 kg/ha. La tasa del 100% de aplicación fue el control, mientras que el 70 y 30% fueron los N tratamientos estresados.

La adquisición de datos espectrales se realizó utilizando un espectrómetro de fibra óptica en miniatura que mide la reflectancia en el rango espectral de 200 a 1150 nm. Además de los índices anteriormente reportados para detectar el estrés hídrico, se reportaron que el RDVI,  $PRI_{norm}$  y TCARI tuvieron la mejor

correlación con los indicadores de estrés por nitrógeno. Y se concluyó que el  $PRI_{norm}$  fue el índice más sensible para detectar el efecto combinado del estrés hídrico y el nitrógeno.

Mwinuka *et al.*, (2020) realizó un estudio en plantas de tomate (*Solanum aethopicum* L) utilizando un diseño de bloques al azar. Los experimentos consistieron en subparcelas que se regaron al 100%, 80% y 60% de los que requiere el cultivo mediante un sistema de goteo, provocando así un estrés en la planta relacionado con el estado hídrico. Se aplicaron diferentes índices de vegetación, en donde resaltaron que el GNDVI fue el que respondió bien durante el 80% de la etapa vegetativa. En conclusión, el NDVI y el OSAVI lograron detectar las diferencias en el contenido de la humedad de la hoja de la planta en todos los tratamientos de agua durante las etapas vegetativa y vegetativa completa.

Al siguiente año, Qi *et al.*, (2021) realizó un estudio en dos tipos de frijol, y calcularon ocho índices de vegetación utilizando fotografías multiespectrales obtenidas con un VANT. Se resalta que el modelo de regresión lineal unidimensional del NDVI y GNDVI tuvieron un grado de ajuste mayor que los otros índices aplicados.

Se puede destacar que existe un incremento en los últimos años en estudios relacionados con la AP apoyándose en el uso de IV para conocer las condiciones en las que se encuentra el cultivo en estudio. En donde los autores explican la diferencia en la sensibilidad entre índices, teniendo como variantes distintas entre estudios; diferentes cultivos, condiciones climáticas, sensores, suelo y formas de recolección de datos.

Además, considerando que existen un gran número de índices multiespectrales e hiperespectrales que ayudan a detectar el estado del cultivo. Sin embargo, no todos los IV son óptimos para el monitoreo de cualquier cultivo, ya que las diferencias de localización y especie de plantaciones pueden llegar a afectar los resultados obtenidos.

De igual forma, también existe un incremento de estudios enfocados en la adquisición de datos con la ayuda de un VANT, dándonos así la ventaja de controlar más aspectos relacionados a la resolución. Sin embargo, en la gran mayoría de estudios relacionan los datos de clorofila obtenidos de forma manual contra los obtenidos con un VANT.

## **2.3 Agricultura de precisión**

Existen muchas definiciones al momento de describir la AP, sin embargo, siempre implica una estrategia de gestión que utiliza un conjunto de técnicas avanzadas de información, comunicación y análisis de datos en el proceso de la toma de decisiones; por ejemplo, la gestión de la aplicación de agua, fertilizantes, pesticidas, semillas, combustible, manos de obra, entre otros factores, lo que ayuda a mejorar la producción

de los cultivos, reducir las pérdidas de agua, nutrientes y los impactos ambientales negativos propio de la agricultura (Sishodia *et al.*, 2020).

Los avances de la información geoespacial y las tecnologías de la comunicación han permitido gestionar las variables espaciales y temporales (suelo, región, entre otros) con mucha más precisión que antes. La AP, por tanto, se diferencia de la agricultura convencional porque implica determinar la variación con mayor precisión y vincular las relaciones espaciales a la gestión (Srinivasan, 2006). Lo que conduce a obtener beneficios, los cuales resultan en una reducción de costos; optimización de la cosecha y calidad en relación con la capacidad productiva del lugar; mejor gestión de los recursos; y protección al medio ambiente.

Actualmente, las tecnologías emergentes, como la PR, GNSS, SIG, el Internet de las Cosas, el análisis de Big Data y la inteligencia artificial son herramientas que ayudan en la optimización de las operaciones y los insumos agrícolas (Zhang, 2016).

## 2.4 Fotogrametría

Podemos definir la fotogrametría como el arte, la ciencia y la tecnología de obtener información fiable sobre objetos físicos y el entorno mediante procesos de registro, medición e interpretación de imágenes fotográficas y patrones de energía electromagnética radiante registrada y otros fenómenos (Wolf *et al.*, 2014). La fotografía y fotogrametría comenzaron casi a la par, por lo que ha existido una emigración de la fotogrametría analógica a las imágenes digitales y visión por computadora (Sholarin & Awange, 2015).

La fotogrametría se ocupa principalmente de realizar mediciones precisas de objetos tridimensionales y características del terreno a partir de fotografías bidimensionales. Las aplicaciones que se le pueden dar son; medición de coordenadas; cuantificación de distancias, alturas, áreas y volúmenes; elaboración de mapas topográficos; y generación de modelos digitales de elevación y ortofotografías (Sholarin & Awange, 2015).

Los avances en la instrumentación y las técnicas de fotogrametría han continuado a un ritmo rápido desde sus inicios. Como es el caso del avance a la fotogrametría digital, la cual ayudo a obtener una mayor calidad y precisión; además, el uso de VANTs permiten una mayor rapidez en la obtención de imágenes, resolución y acceso a terrenos que cuenten con una mayor dificultad de acceso (van der Merwe *et al.*, 2020). Estos avances en conjunto han permitido que la fotogrametría se convierta en el método más preciso y eficiente para compilar mapas y generar información.

Podemos dividir la fotogrametría en dos tipos: aérea, la cual se realiza con una cámara desde el aire; y terrestre, con fotografías realizadas manualmente o con la ayuda de un tripié. La fotogrametría aérea de formato pequeño tiene lugar en cierto modo entre estos dos tipos, combinando el punto de vista aéreo con distancias cercanas al objeto y gran detalle de la imagen (Sholarin & Awange, 2015).

Una fotografía es el resultado de una proyección central, también conocida como perspectiva de un solo punto. Por lo que, las distancias del punto central de convergencia al centro óptico de la lente de la cámara, o exposición estacionada al sensor de un lado y al objeto del otro lado (Sholarin & Awange, 2015), determinan la escala:

$$S = 1/s = f/H_g = d/D \quad (2.7)$$

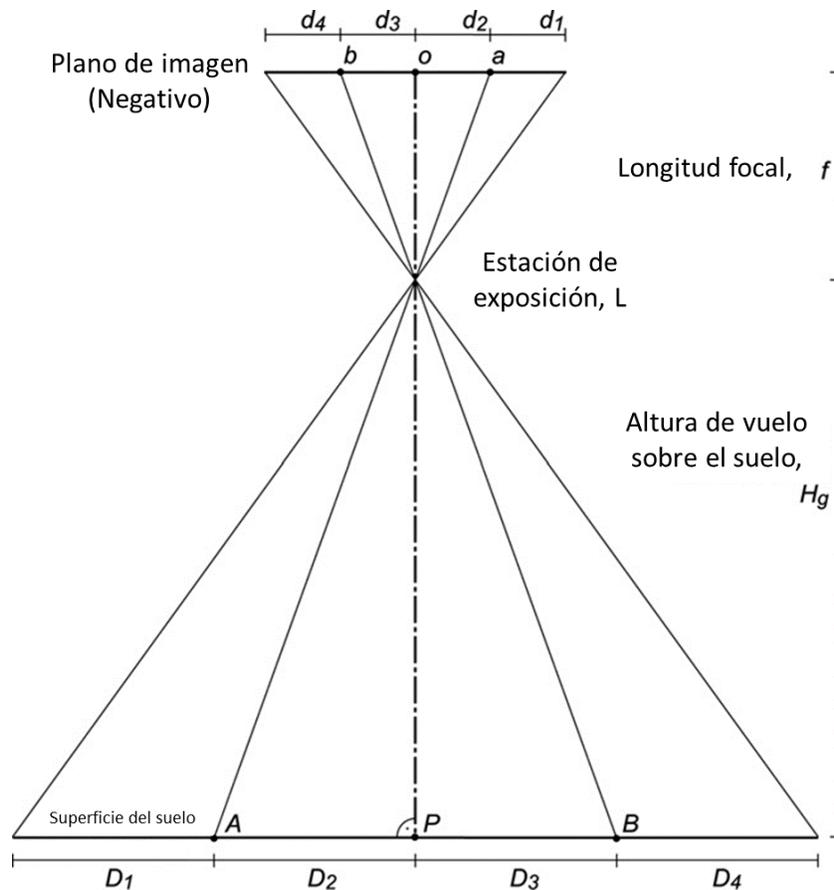
Donde  $D$  representa la distancia terrestre,  $H_g$  es la altura de vuelo sobre el suelo,  $d$  representa la distancia de la foto,  $f$  corresponde a la distancia focal. Esta misma ecuación es de utilidad para la obtención de  $H_g$ :

$$H_g = f \times s \quad (2.8)$$

Para la determinación de la resolución espacial en imágenes digitales se utiliza el GSD, la cual hace uso del tamaño exacto de la celda del sensor, el cual se obtiene de la información del fabricante.

$$GSD = \frac{\text{tamaño de la celda del sensor} \times H_g}{f} \quad (2.9)$$

En la Figura 2.1 se muestra el caso ideal de la obtención de imágenes de forma digital para fotogrametría en un terreno plano. Sin embargo, en una situación habitual nos encontramos que el suelo no es completamente plano, por lo que la diferencia entre el plano de la imagen y el suelo varía dentro de la imagen, también nos encontramos las situaciones de que las fotografías no son completamente verticales (el eje óptico no es perpendicular al suelo) y la proyección es imperfecta debido a las distorsiones de la lente en sí (Sholarin & Awange, 2015). Estas situaciones en la toma de las fotografías dan como resultado variación en la escala y distorsiones de los objetos.



**Figura 2.1.** Fotografía vertical tomada sobre un terreno completamente llano. El eje óptico, que corta el plano de la imagen en su centro o, se encuentra con el suelo en ángulo recto en el punto principal P.  
Fuente: (Sholarin & Awange, 2015)

## 2.5 Percepción remota

La vista de los seres humanos presenta grandes limitaciones, ya que solo permite apreciar un determinado tipo de energía, la cual se conoce por esta misma razón como espectro visible. Fuera de este rango, el ojo humano no es capaz de ver algo; debido a la necesidad de incorporar más espectros se hace uso de la tecnología, logrando desarrollar sensores artificiales que permiten observar rangos espectrales específicos. Estos sensores artificiales pueden ser montados sobre plataformas situadas a diferentes altitudes, con la ayuda de aviones (tripulados o no tripulados) y/o satélites. Esto permite tener acceso a tipos de energía no detectables por el ojo humano (ultravioleta, infrarrojo, microondas) (Chuvieco, 1995).

La tecnología que engloba los procesos que permiten obtener una imagen de la superficie de la tierra desde el aire o el espacio, y su posterior tratamiento en el contexto de una determinada aplicación, se denomina PR, teledetección o tele-observación; dichos vocablos son la traducción latina del término inglés *remote sensing* (Villegas Vega, 2008).

La PR es el proceso de detección y seguimiento de las características físicas de un área midiendo su radiación reflejada y emitida a distancia (desde satélites o aviones), esta radiación puede ser de origen natural (detección remota pasiva) o producida por instrumentos (detección remota activa) (Frauenfelder, 2021). Tal definición implica que entre la superficie de la tierra y el sensor debe existir una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial, o por emisión propia. A su vez, es preciso que ese haz energético recibido por el sensor se transmita a la superficie terrestre, donde la señal detectada pueda almacenarse y, en última instancia, ser interpretada para una aplicación determinada (Villegas Vega, 2008). Otra definición para la PR es la técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible, es preciso que entre los objetos y el sensor exista algún tipo de interacción (Chuvieco, 1995).

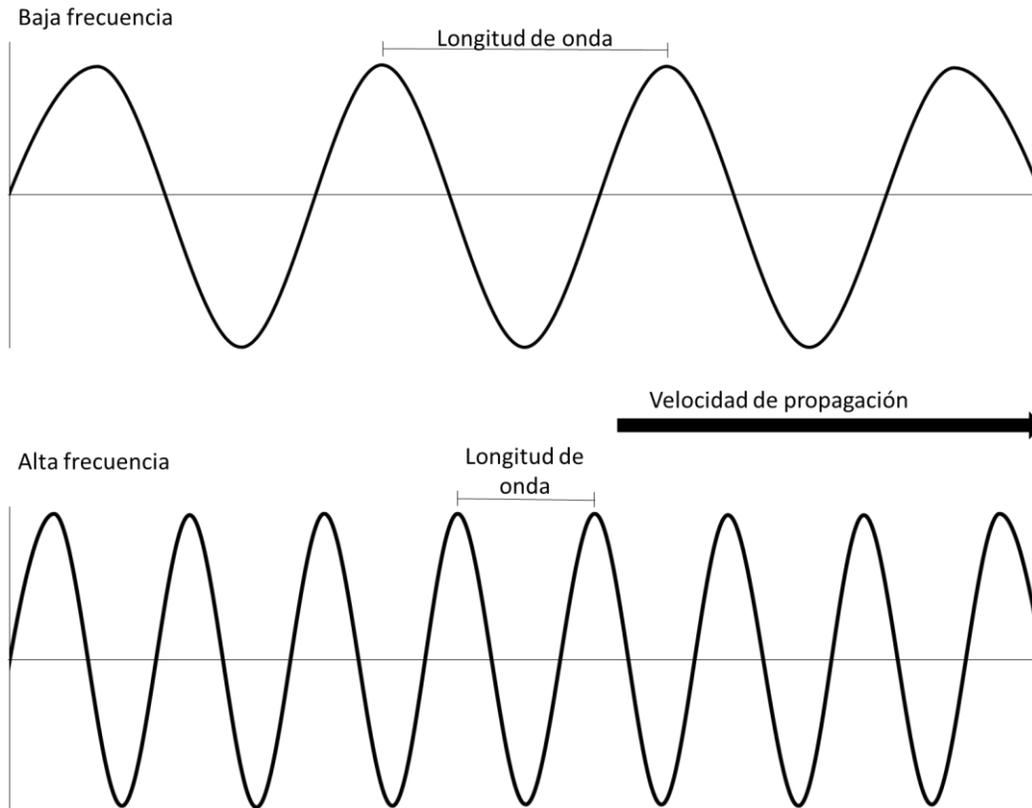
La PR tiene un rango amplio de aplicaciones, entre las que se encuentran el ámbito militar, aunque no son de interés en el presente documento. La mayoría de las aplicaciones se pueden clasificar de forma general como medioambientales, y a su vez se distinguen una serie de variables ambientales: en la atmósfera, la superficie terrestre y en el océano (Sandwell, 2013). Como ejemplo de estas variables se tiene que, en la atmósfera se detecta la temperatura, precipitación, nubosidad, velocidad del viento, concentraciones de diversos gases, entre otras; sobre la superficie terrestre se distingue el movimiento tectónico, topografía, vegetación, temperatura, reflectancia y contenido de humedad del suelo; y sobre la superficie del océano se puede aplicar para la obtención de la temperatura, mareas, corrientes, hielo marino, entre otras.

## 2.6 Espectro electromagnético

La energía electromagnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas ortogonales entre sí: eléctrico y magnético. Las características de este flujo energético pueden describirse por dos elementos: longitud de onda ( $\lambda$ ) y frecuencia ( $F$ ) (Figura 2.2). La primera hace referencia a la distancia entre dos picos sucesivos de una onda mientras que la frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo (Chuvieco, 1995). Ambos elementos están inversamente relacionados, como describe la siguiente fórmula:

$$c = \lambda F \quad (2.10)$$

Donde  $c$  indica la velocidad de la luz ( $3 \times 10^8 \text{ m/s}$ )  $\lambda$  expresa la longitud de onda y  $F$  la frecuencia.



**Figura 2.2.** Longitud de onda y frecuencia.

Se puede describir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. La organización de las bandas de longitud de onda o frecuencia se denomina espectro electromagnético (Figura 2.3). Comprende, en un continuo, desde las longitudes de onda más corta (rayos gamma, rayos X), hasta longitudes de onda que comprenden kilómetros (telecomunicaciones) (Chuvienco, 1995). Desde el punto de vista de PR, conviene destacar una serie de bandas espectrales, que son las empleadas con más frecuencia:

- Espectro visible ( $0.4$  a  $0.7 \mu m$ ). Se denomina así por tratarse de la única radiación electromagnética que puede percibir el ojo humano, coincidiendo con las longitudes de onda en donde es máxima la radiación solar. Suelen distinguirse tres bandas elementales, que se denominan azul ( $0.4$  a  $0.5 \mu m$ ); verde ( $0.5$  a  $0.6 \mu m$ ), y rojo ( $0.6$  a  $0.7 \mu m$ ), en razón de los colores elementales asociados a esas longitudes de onda.
- Infrarrojo próximo ( $0.7$  a  $1.3 \mu m$ ). A veces se denomina también infrarrojo reflejado y fotográfico, puesto que puede detectarse a partir de films dotados de emulsiones especiales. Resulta de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.
- Infrarrojo medio ( $1.3$  a  $8 \mu m$ ). En donde se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre.

- Infrarrojo lejano o térmico (9 a 14  $\mu\text{m}$ ). Que incluye la porción emisiva del terreno terrestre.
- Microondas (a partir de 1 mm). Con gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa.

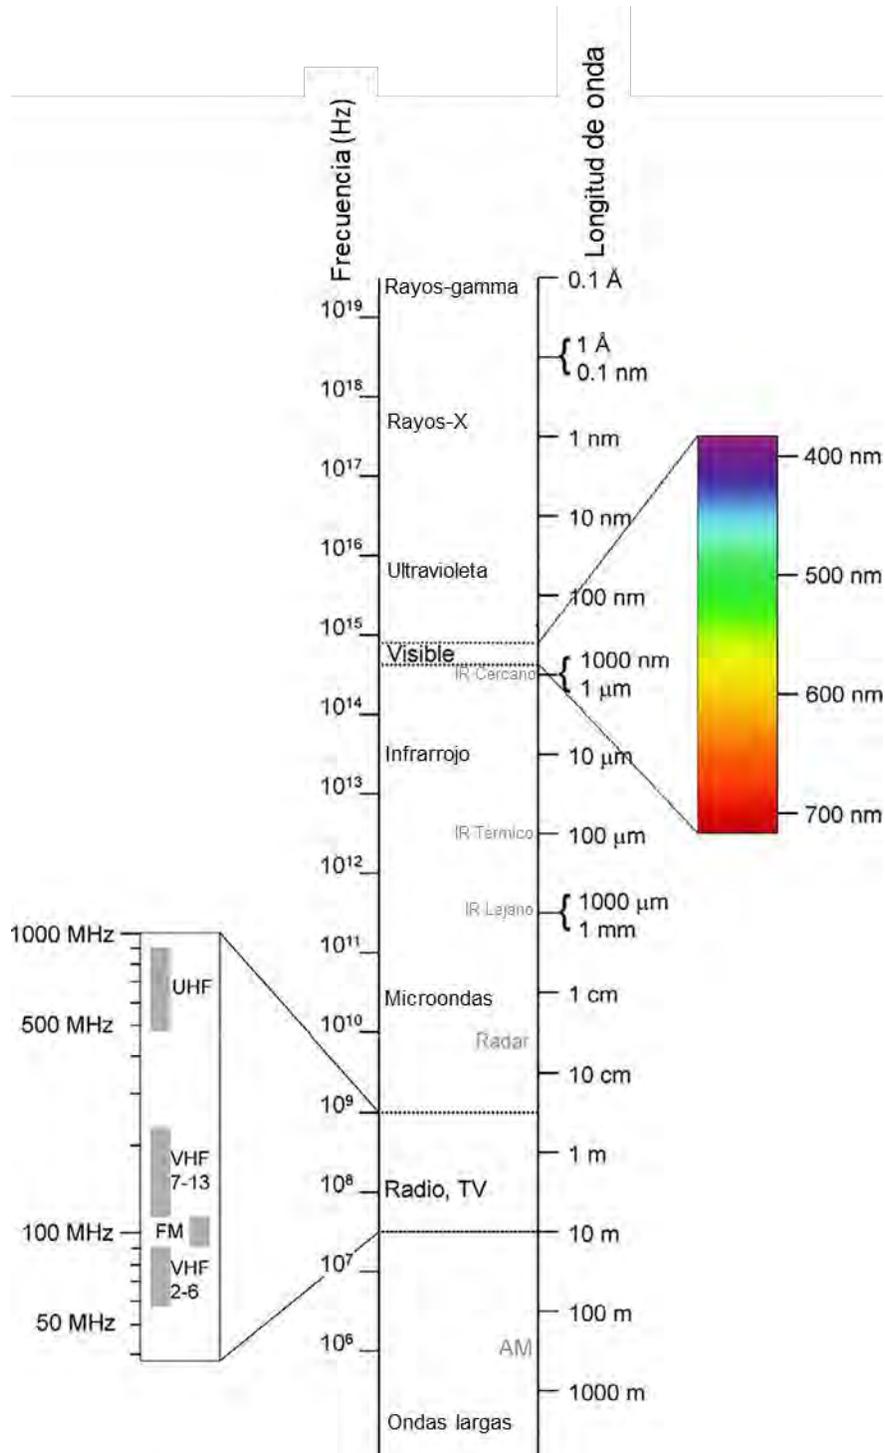


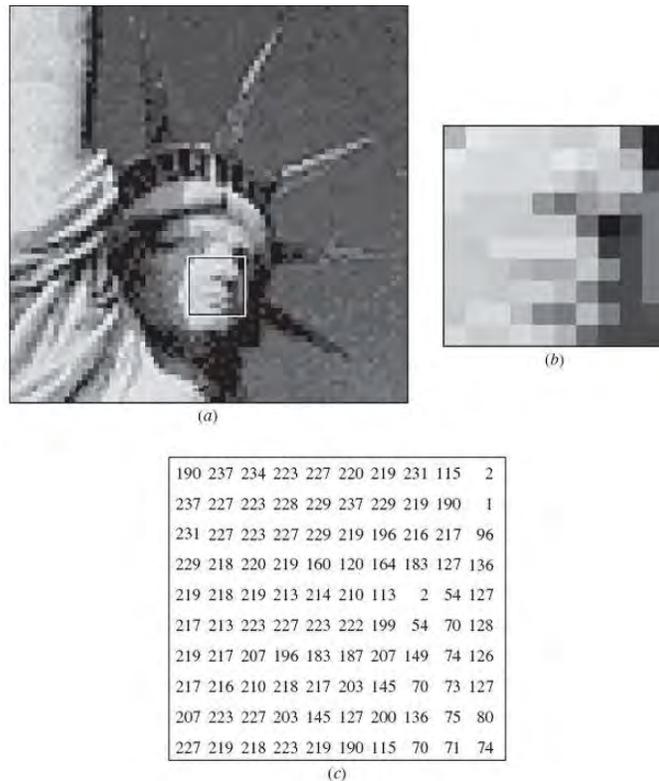
Figura 2.3. Espectro electromagnético. Fuente: (Frauenfelder, 2021).

## 2.7 Imágenes

Se puede definir una imagen como la representación de la forma externa de una persona o cosa en el arte. También es una impresión visible obtenida por una cámara, un telescopio, un microscopio u otro dispositivo, o mostrada en la pantalla de un computador. Para este propósito, una imagen es una representación bidimensional de una superficie producida por cualquier dispositivo que tenga la capacidad de obtener información en una dirección  $x$  y  $y$  de la superficie en una forma correlativa (Amigo, 2020).

### 2.7.1 Imagen digital

Para el caso de una imagen digital la podemos definir como una función de dos dimensiones:  $f(x, y)$ , 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 (Gonzalez & Woods, 2008). De hecho, una imagen consta de una matriz de números enteros, a menudo denominados números digitales, cada uno de los cuales cuantifica el nivel de gris, o grado de oscuridad en un elemento en particular (Wolf *et al.*, 2014). Estos números digitales de una imagen son llamados píxeles. Esto se ilustra de forma más clara en la Figura 2.4.



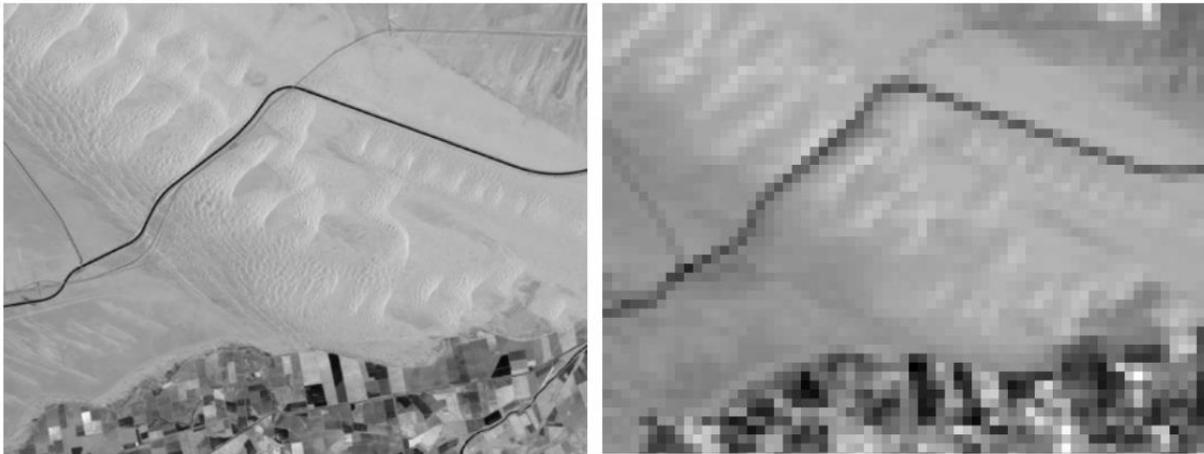
**Figura 2.4.** a) imagen de ejemplo, b) porción de la imagen, c) Números digitales asociados con su posición. Fuente: (Wolf *et al.*, 2014).

## 2.8 Resolución

La resolución se define como la capacidad del sistema para presentar la información en la menor cantidad discretamente separable en términos de distancia (espacial), banda de longitud de onda electromagnética (espectral), tiempo (temporal) y/o cantidad de radiación (radiométrica) (Mason & Schmetz, 1992).

### 2.8.1 Resolución espacial

La resolución espacial es la proyección de un elemento detector o una rendija en el suelo. En otras palabras, la resolución espacial del sensor es el segmento de tierra detectado en cualquier instante. La resolución espacial a la que se adquieren los datos tiene dos efectos: la capacidad de identificar varias características y cuantificar su extensión. El primero se relaciona con la precisión de la clasificación y la capacidad de realizar mediciones con precisión. Se dice que las imágenes en las que solo son visibles características grandes tienen una resolución gruesa o baja. En imágenes de alta resolución, se pueden detectar objetos pequeños (Mason & Schmetz, 1992).

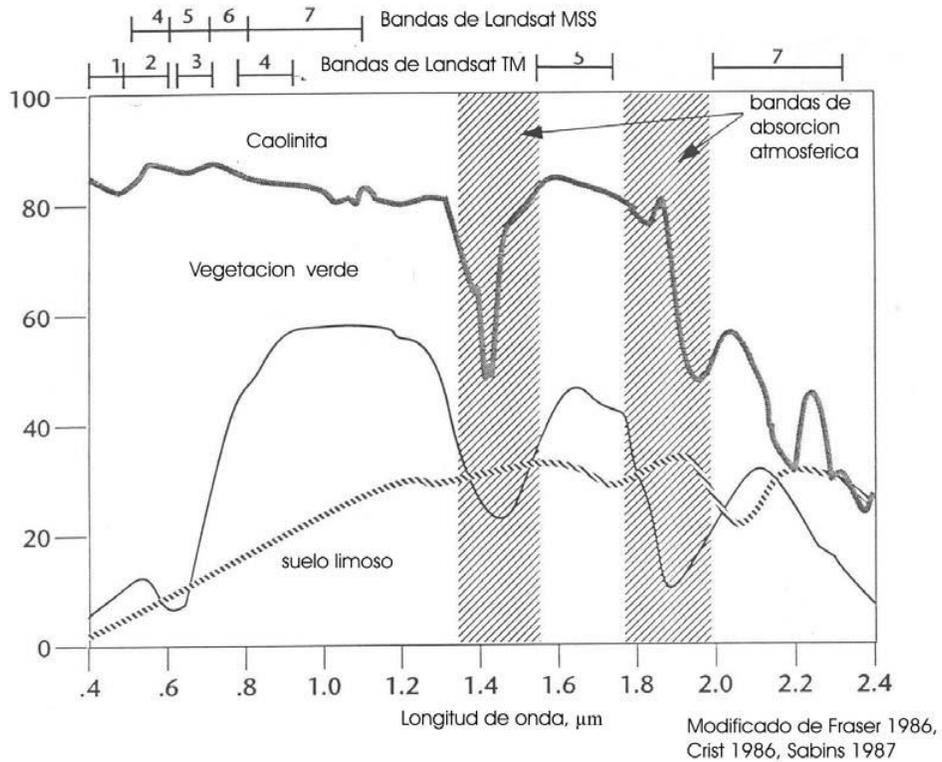


**Figura 2.5.** Ejemplo de resolución espacial. Fuente: (Schowengerdt, 2007)

### 2.8.2 Resolución espectral

La emisividad espectral caracteriza la reflectancia y/o emitancia de una característica u objetivo en una variedad de longitudes de onda. Se pueden distinguir diferentes características y detalles en una imagen comparando sus respuestas en distintos rangos de longitud de onda. Las clases amplias, como el agua y la vegetación, se pueden separar utilizando rangos de longitud de onda amplios (VIS, NIR), mientras que clases específicas como los tipos de rocas requieren una comparación de rangos de longitud de onda finos para separarlos. Por lo tanto, la resolución espectral describe la capacidad del sensor para definir intervalos de longitud de onda finos, es decir, muestrear la imagen segmentada espacialmente en diferentes

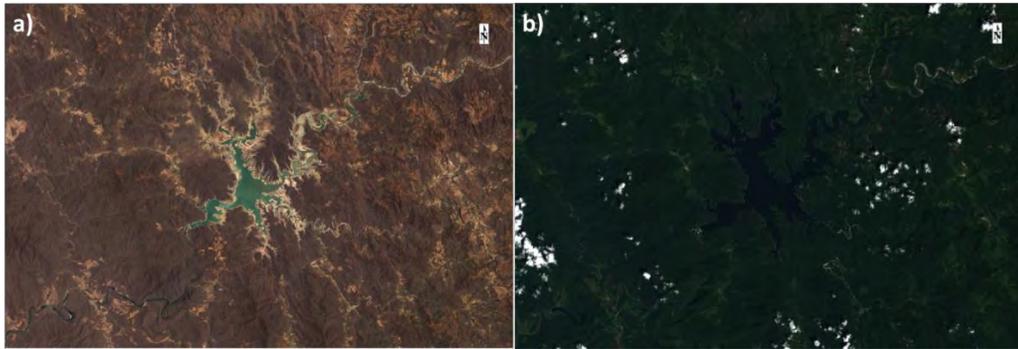
intervalos espectrales, lo que permite determinar la irradiancia espectral de la imagen (Mason & Schmetz, 1992).



**Figura 2.6.** Curvas de reflectancia espectral de la caolinita, la vegetación y el suelo. Fuente: (Villegas, 2008).

### 2.8.3 Resolución temporal

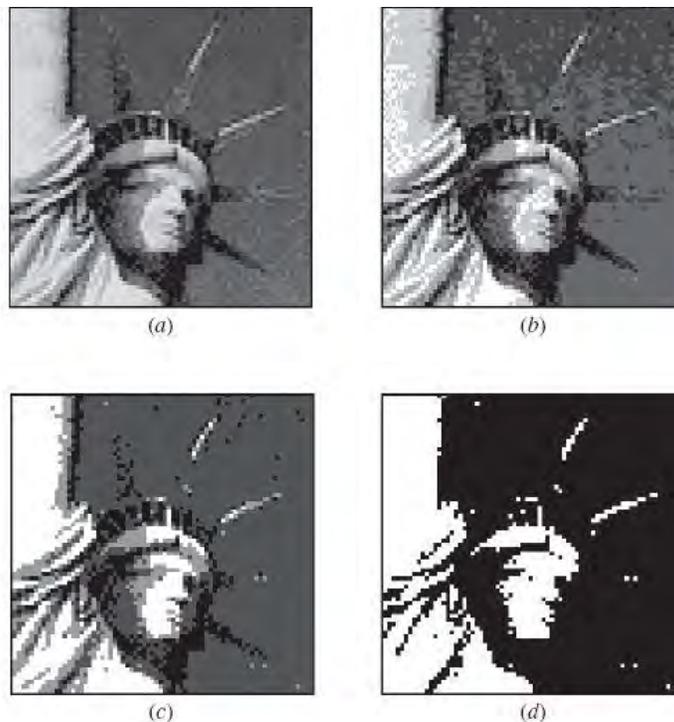
La resolución temporal se refiere a la obtención de datos espaciales y espectrales en determinados intervalos de tiempo. La resolución temporal también se denomina repetitividad; es la capacidad del sensor para obtener imágenes de la misma área exacta con el mismo ángulo de visión en diferentes períodos de tiempo (Figura 2.7). La resolución temporal de un sensor depende de una variedad de factores, incluidas las capacidades del satélite/sensor, la superposición de franjas y la latitud (Mason & Schmetz, 1992).



**Figura 2.7.** Imagen de la presa Sanalona ubicada en Culiacán, Sinaloa, México, obtenida del satélite de Landsat 8 OLI/TIRS. La imagen a) fue captada en el mes de mayo del 2021, mientras que la imagen b) fue captada en septiembre del mismo año.

## 2.8.4 Resolución radiométrica

La resolución radiométrica es una medida del sensor para diferenciar el cambio más pequeño en la reflectancia/emisancia espectral entre varios objetivos. La resolución radiométrica depende de la radiancia de saturación y del número de niveles de cuantificación. Por lo tanto, un sensor cuya saturación se establezca en un 100% de reflectancia con una resolución de 8 bits tendrá una sensibilidad radiométrica pobre en comparación con un sensor cuya saturación radiante se establezca en un 20% de reflectancia y una digitalización de 7 bits (Mason & Schmetz, 1992).



**Figura 2.8** Ejemplo de resolución radiométrica. a) muestra la imagen original de 256 niveles de cuantificación, b) muestra la misma imagen con 8 niveles, c) con 4 niveles y d) con 2 niveles. Fuente: (Wolf *et al.*, 2014).

## 2.9 Imágenes multispectrales

Existen diferentes tipos de clasificación de una imagen. Una de las formas más adecuadas es considerando la cantidad de información que puede contener un píxel. La información puede provenir de una simple diferencia de intensidades con respecto a una frecuencia, generando un único canal de información por píxel. Hoy en día es habitual encontrar imágenes que contienen más canales de información por cada píxel. Una de ellas son las imágenes multispectrales (Amigo, 2020).

Las imágenes multispectrales, o también llamadas multibanda, son aquellas que capturan imágenes individuales en números de onda o longitudes de onda específicas (Figura 2.9), frecuentemente tomadas por filtros o LEDs específicos, a través del espectro electromagnético (normalmente las regiones VIS y NIR) (Amigo, 2020).

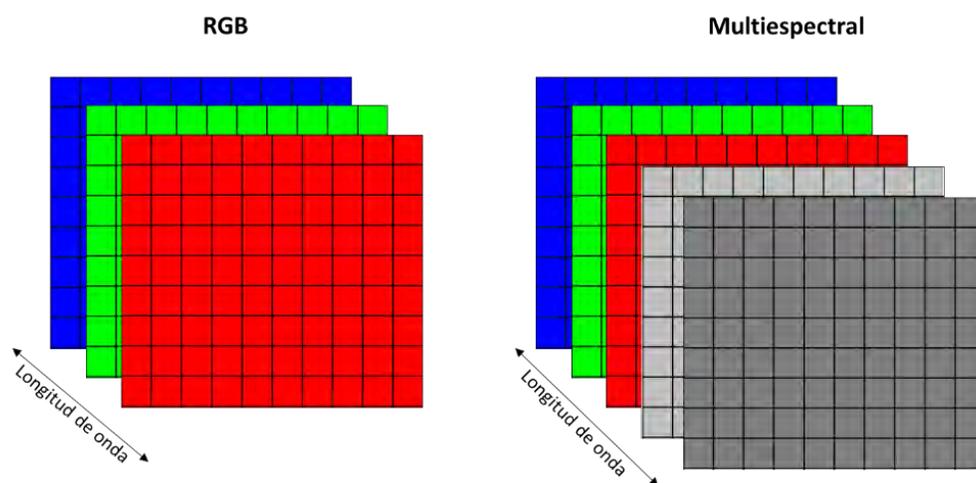
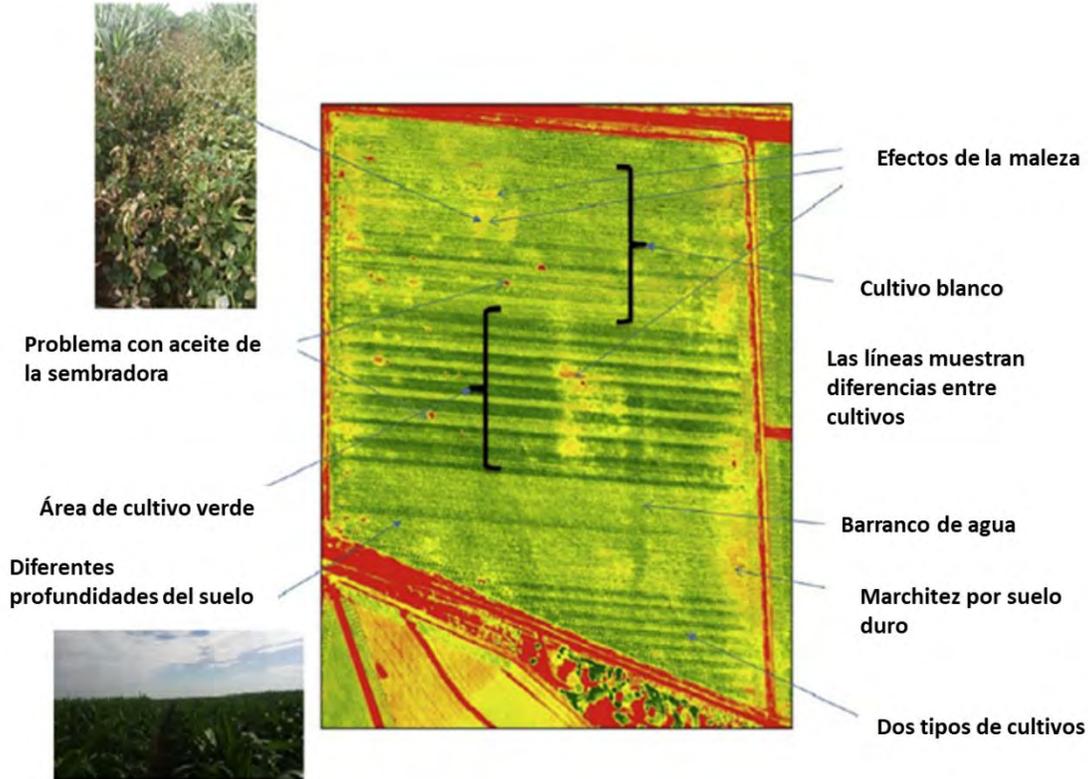


Figura 2.9. Representación gráfica de una imagen RGB con una multispectral.

## 2.10 Índices de vegetación

La radiación solar reflejada por las plantas depende de sus características químicas y morfológicas. El tipo de planta, el contenido de agua y las características del dosel afectan a la luz reflejada en cada banda espectral de forma diferente (Sishodia *et al.*, 2020). Por lo que, las mediciones de la luz reflejada con la ayuda de filtros se han utilizado comúnmente para desarrollar varios IV que ayudan en la obtención de información para conocer las condiciones en las que se encuentra la planta y estructura (Figura 2.10).

Los IV son expresiones matemáticas que combinan la reflectancia medida en muchas bandas espectrales para producir un valor que ayuda a evaluar el crecimiento de los cultivos, el vigor y otras propiedades de la vegetación, como la biomasa y el contenido de clorofila. La cartografía de estos índices puede ayudar a comprender la variabilidad espacio-temporal de las condiciones de los cultivos, lo que es crucial para las aplicaciones de la AP (Sishodia *et al.*, 2020).



**Figura 2.10.** Mapa de NDVI de un campo de maíz, derivado de imágenes aéreas de alta resolución espacial, que demuestra el poder de la resolución espacial fina para ayudar en la identificación de las causas de la variabilidad dentro de un campo de cultivo. Fuente: (van der Merwe *et al.*, 2020)

## 2.11 Características de la vegetación en el espectro óptico

Acorde con Chuvieco (1995), la caracterización espectral de las masas vegetales ofrece dificultades provocadas por los múltiples factores que influyen en la radiancia final detectada por el sensor. En primera instancia, ha de considerarse la propia reflectividad de la hoja, en función de su estado fenológico, forma y contenido de humedad. Además, es preciso tener en cuenta las características morfológicas de la planta: altura, perfil, grado de cobertura del suelo, entre otras, que provocan una notable modificación de su comportamiento reflectivo. Un tercer grupo de factores serían los derivados de la situación geográfica de la planta: pendiente, orientación, asociación con otras especies, geometría de plantación, entre otros.

Asimismo, Chuvieco menciona que las características espectrales se reflejan, primordialmente, con la acción de los pigmentos fotosintéticos y del agua que almacenan las hojas. En concreto, la baja reflectividad en la porción visible del espectro se debe al efecto absorbente de los pigmentos de la hoja, principalmente:

clorofilas, xantofilas y carotenos (65, 29 y 6% respectivamente, aunque pueden variar). Todos ellos absorben en la banda del espectro situada en torno a  $0.445 \mu m$ , mientras la clorofila presenta una segunda banda de absorción en torno a los  $0.645 \mu m$ . Entre ambas porciones del espectro, aparece una banda intermedia ( $0.55 \mu m$ ), en donde el efecto absorbente es menor. Por esta causa parece un pico relativo de reflectividad que coincide con la banda verde del espectro VIS, y causa el color que nuestros ojos perciben. En cuanto a la elevada reflectividad en el NIR, parece deberse a la estructura celular interna de la hoja. En concreto, la capa esponjosa del mesófilo, con sus cavidades de aire internas, ejerce un papel protagonista, al difundir y dispersar la mayor parte de la radiación incidente en esta banda del espectro. Por ello, la hoja sana ofrece una alta reflectividad en el NIR (entre  $0.7$  y  $1.3 \mu m$ ), en claro contraste con la baja reflectividad que ofrece en el espectro VIS, especialmente con la banda roja. Puesto que la estructura de la hoja es muy variada según las especies.

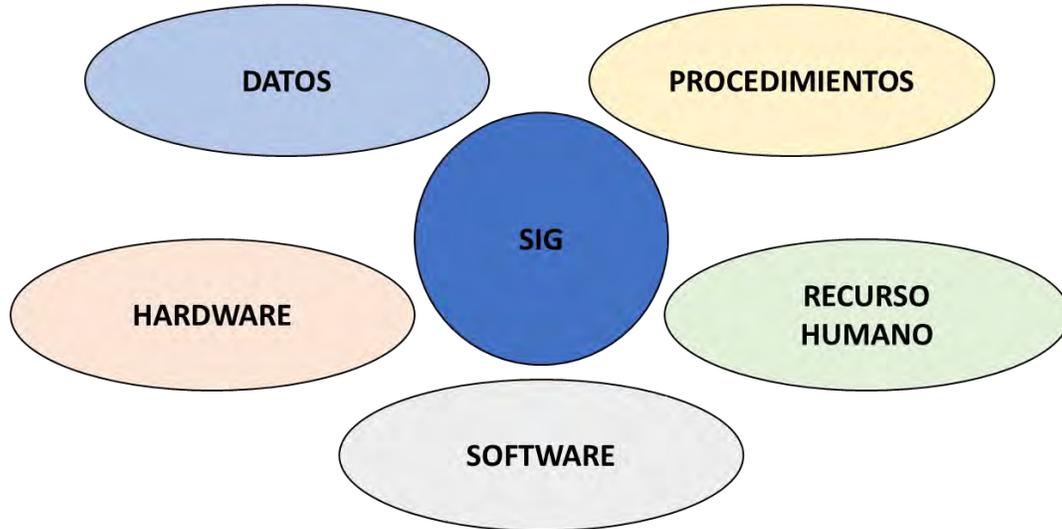
Chuvieco también destaca que, a partir de  $1.4 \mu m$  el efecto absorbente del agua es muy claro, por lo que la reflectividad de la vegetación sana se reduce drásticamente en el infrarrojo medio. Las medidas de laboratorio muestran una notable diferencia en esta región del espectro entre las hojas secas y las infiltradas con agua. Las bandas donde la absorción del agua es más clara, se sitúan dos picos relativos de reflectividad, en torno a  $1.6 \mu m$  y  $2.2 \mu m$ . Por lo que la observación en esta región del espectro es de gran interés para conocer el estado de vigor de la hoja, en función de su contenido de humedad. Por lo que estas curvas de reflectividad pueden modificarse en función de la morfología de la hoja. Así, las hojas aciculares tienden a tener una mayor absorción en todas las longitudes de onda, mientras que las plantas desérticas, el tronco suculento, refleja una mayor radiación que otras especies mesolíticas (Chuvieco, 1995).

## 2.12 Sistema de información geográfico

Un SIG es una herramienta la cual ayuda a elaborar y utilizar información espacial. Existen muchas definiciones de SIG, dependiendo del punto de vista que asuma el autor; una de ellas considera que un SIG es un sistema informático que ayuda a la colección, mantenimiento, almacenamiento, análisis, producción y distribución de datos e información espacial (Bennett & Armstrong, 2010). Otra definición de los SIG es una tecnología integradora que unas varias disciplinas con el objetivo común del análisis, creación, adquisición, almacenamiento, edición, transformación, visualización, distribución, etc. de información geográfica (Gómez, 2006). A pesar de ser conceptos distintos, se observan ciertos elementos en común.

Un SIG está compuesto por el hardware, software, datos, recurso humano y procedimientos (Figura 2.11). Estos componentes deben estar bien integrados para el buen uso del SIG, y el desarrollo y la integración de estos compuestos es un proceso continuo e iterativo (Bennett & Armstrong, 2010). Por lo que un SIG puede entenderse como una “caja de experimentación”, permitiendo plantear diferentes escenarios

virtuales de una determinada región; por una parte, los que se producirán con la ejecución de ciertas políticas o los que ocurrirían siguiendo determinadas tendencias. Todo esto hace de los SIG una potente herramienta de planificación cuando se dispone de una base de datos suficientemente amplia para los fines que se plantean (Gómez, 2006).



**Figura 2.11.** Componentes de un SIG.

## 2.13 Tomate

El tomate pertenece a la familia Solanaceae. Es una planta dicotiledónea y herbácea perenne, que se cultiva en forma anual para el consumo de sus frutos. La fenología está determinada por la variedad y las condiciones climáticas de la zona donde se establece el cultivo (Lopez, 2017). Las etapas se pueden dividir en cinco periodos:

1. Establecimiento de la planta joven: Constituye el periodo de formación inicial de las partes aéreas de la planta, conocido como desarrollo del semillero.
2. Crecimiento vegetativo: Comprende los primeros 40 a 45 días desde la siembra de la semilla, después de los cuales las plantas comienzan su desarrollo continuo. A esta etapa le siguen cuatro semanas de crecimiento rápido.
3. Floración e inicio del cuaje de la planta: Este periodo se extiende desde el inicio de la floración (de 20 a 40 días del trasplante) hasta la finalización del ciclo de crecimiento de la planta. El cuaje tiene lugar cuando la flor es fecundada y empieza el proceso de su transformación en fruto.
4. Inicio del desarrollo de la fruta: El cuaje de la planta ocurre luego de la polinización. En esta etapa una vez iniciado su crecimiento, la fruta no suele caerse y no presenta rastros de la flor. El crecimiento de la flor y la acumulación de materia seca presentan un ritmo relativamente estable, hasta llegar a dos o tres grados de maduración.

5. Maduración de la fruta: Por lo general la maduración ocurre aproximadamente 80 días después del trasplante, dependiendo del cultivar, la nutrición y las condiciones climáticas. Luego, la cosecha continúa hasta llegar a los 180 a 210 días después del trasplante.

## 3. Materiales y métodos

### 3.1 Área de estudio

El área de estudio se encuentra en la parte sureste del municipio de Navolato, Sinaloa, México. El sitio se encuentra localizado en las coordenadas 24° 40' 35.05"N y 107° 32' 27.99"O (Figura 3.1). La experimentación fue realizada en los meses de octubre del 2021 a enero del 2022. El clima de la zona en estos meses se encuentra con temperaturas máximas de hasta 34°C y con temperaturas mínimas de 13°C aproximadamente.

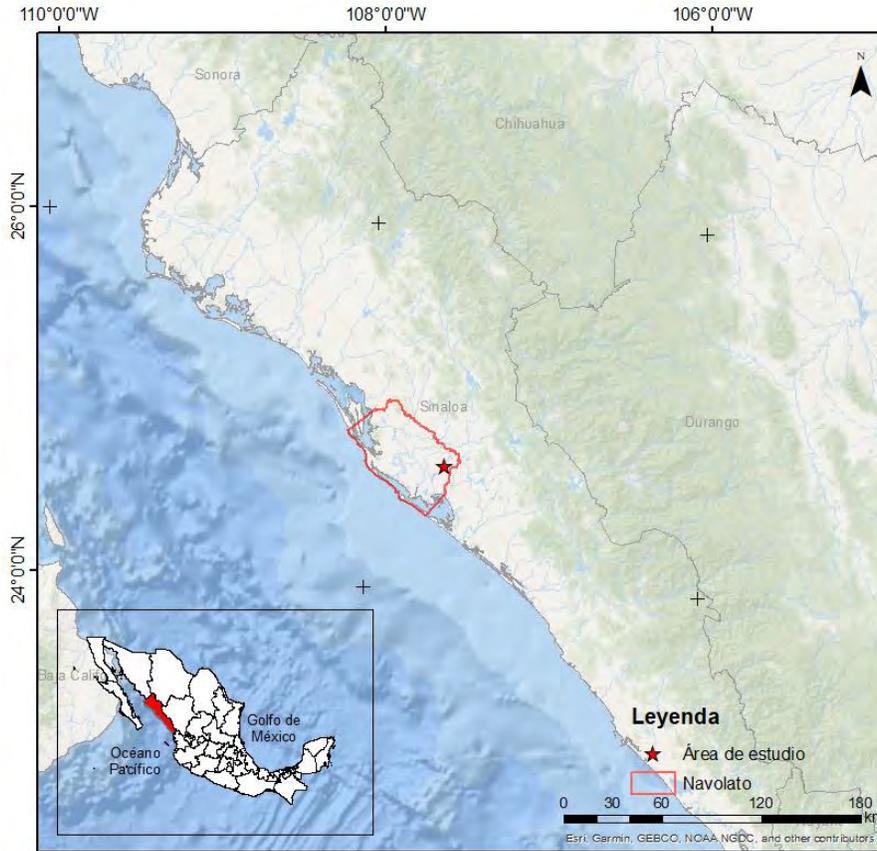


Figura 3.1. Ubicación del área de estudio.

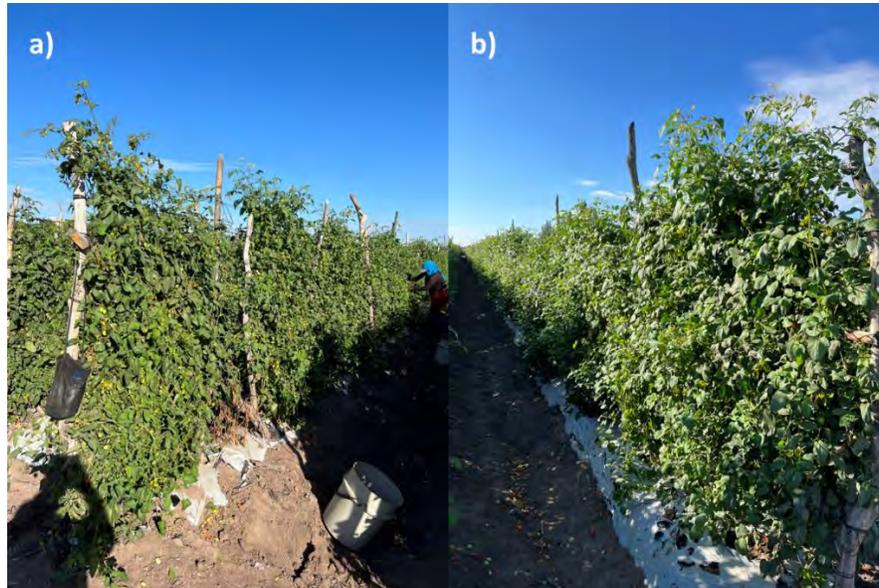
### 3.2 Tipo y condiciones del cultivo

El tipo de cultivo con el que se realizó la experimentación es el tomate cherri (*Solanum lycopersicum* var. *cerasiforme*), trasplantado a cielo abierto el 6 de septiembre del 2021 y con un manejo del cultivo de manera

local; sosteniéndose de forma verticalmente con la ayuda de hilos de nailon, manteniendo así las plantas en orden. El área de estudio fue dividida en dos tablas (secciones) de tratamiento, en donde la tabla 1 (Figura 3.2a) cuenta con un tratamiento habitual (testigo), y la tabla 2 (Figura 3.2b) se le suministra un tratamiento adicional en donde se le suministran más nutrientes, en la Tabla 3.1 se muestra la composición del fertilizante orgánico-mineral suministrado.

**Tabla 3.1.** Composición del fertilizante orgánico-mineral suministrado (KeyPlex 350 OR).

<b>Ingredientes activos y composición</b>	<b>% en peso</b>
Magnesio soluble en agua	1.5
Azufre	4.0
Boro	0.16
Hierro	3.5
Manganeso	0.75
Molibdeno	0.004
Zinc	0.76
Ácido húmico	0.54
Ingredientes inertes	88.045
Total	100



**Figura 3.2.** a) Crecimiento de la planta de tomate en la  $T_1$  y b) crecimiento de la planta de tomate en la  $T_2$  en la fecha 18/12/2021.

Es importante destacar que durante el control del diseño de experimentos no se nos permitió conocer la dosificación de los insumos utilizados por temas de secrecía de parte de la empresa. Lo que la empresa

quería conocer consistió en una validación de sus productos orgánicos, por lo que se optó en comparar el mismo cultivo el cual tuvo un manejo similar, con esta diferencia entre parcelas.

### 3.3 Metodología

El presente esquema metodológico muestra de manera general la metodología que se propuso para la obtención de los resultados, la cual consistió en tres etapas principales (Figura 3.3). La primera etapa se enfoca en el plan de vuelo en campo, el cual toma en cuenta los parámetros del vuelo y la configuración de la cámara multiespectral; la segunda etapa consistió en la calibración y procesamiento fotogramétrico de las imágenes aéreas digitales; en la última etapa se utilizaron algunas técnicas de percepción remota, donde se utilizó álgebra de bandas espectrales y su respectivo análisis estadístico.

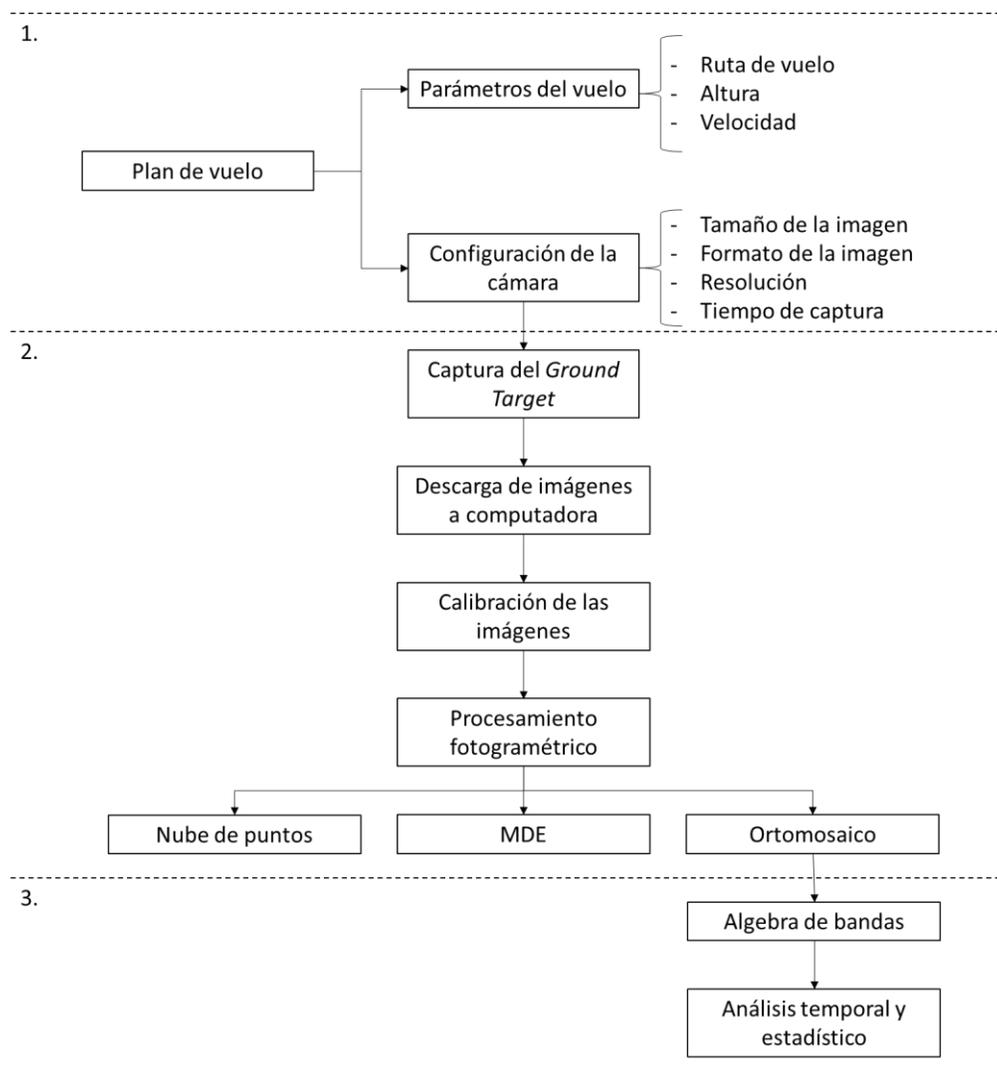


Figura 3.3. Esquema metodológico utilizado.

### 3.4 Adquisición de las imágenes

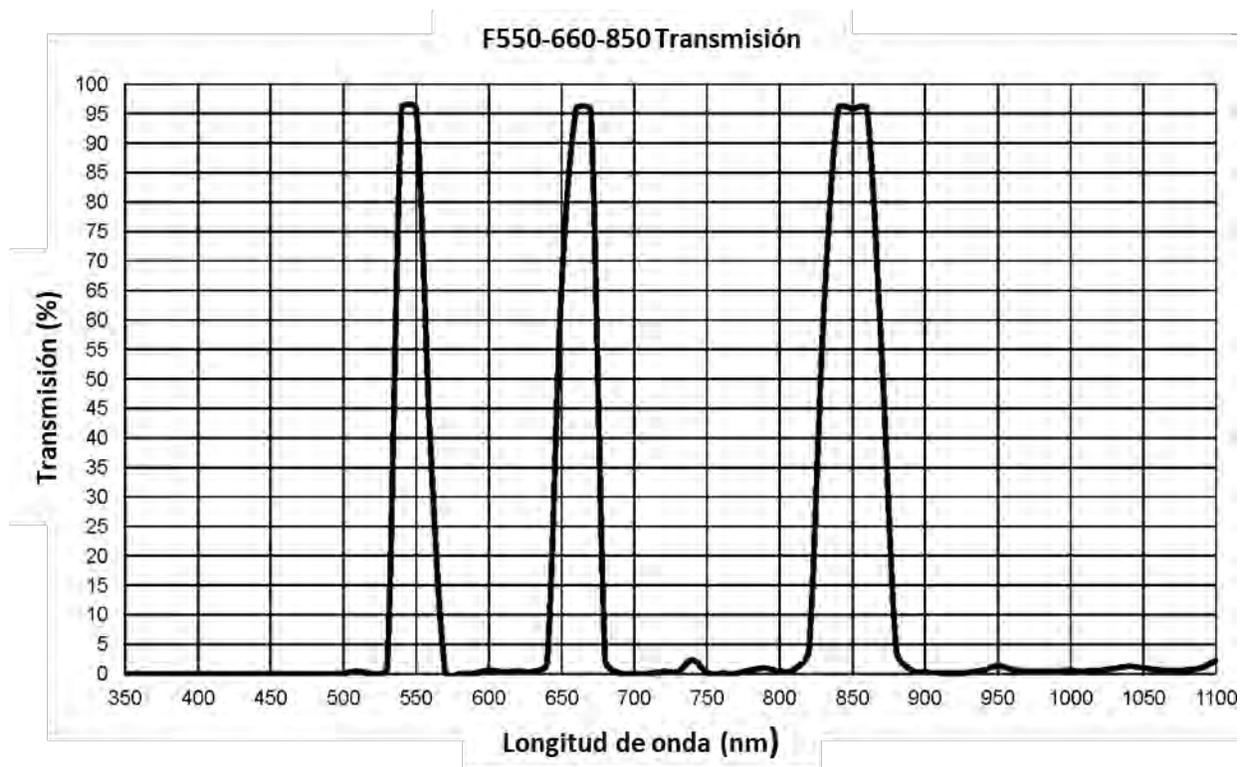
Para obtener un monitoreo de la planta en todas sus etapas de crecimiento, se realizó la primera toma de imágenes en el invernadero. Gran parte de la primera etapa de crecimiento (plántula) se mantuvo en invernadero, por lo que se tuvo que realizar una toma de imágenes de forma manual durante esta fase de crecimiento. Las condiciones en las que se encontraba la planta fueron las óptimas para el momento de trasladarlas al campo. Estas imágenes fueron utilizadas como punto de partida para los análisis posteriores.

Una vez que las plántulas fueron trasplantadas a campo, se llevaron a cabo vuelos para la adquisición de las imágenes multiespectrales utilizando un VANT Phantom 4 Pro, al que con la ayuda de una base externa (Figura 3.4) se le ancló una cámara (MAPIR Survey 3W) la cual obtiene imágenes en un rango espectral del rojo, verde e infrarrojo cercano (RGN). Las bandas se encuentran en las longitudes de onda que se muestran en la Figura 3.5.



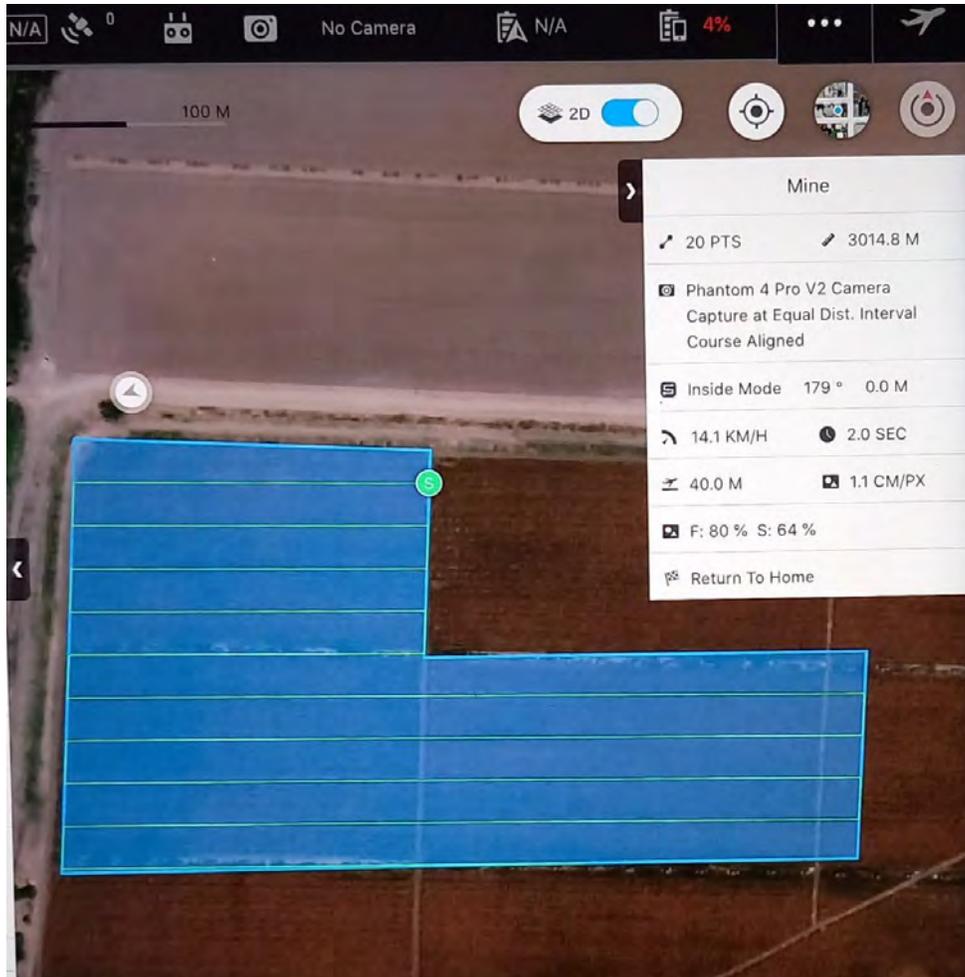
**Figura 3.4.** Phantom 4 Pro con cámara espectral anclada. Fuente: Fotografía propia.

La cámara anteriormente mencionada proporciona los archivos RAW, lo cual representa una ventaja ya que los parámetros de procesamiento pueden ser ajustados libremente con este formato de imagen. Las imágenes capturadas tienen una resolución radiométrica de 12 bits, lo que indica que un píxel en una sola banda es capaz de distinguir 4,096 valores distintos de reflectancia, y en combinación las 3 bandas espectrales pueden indicar hasta 68, 719, 476, 736 valores diferentes del píxel resultante.



**Figura 3.5.** Regiones de longitud de ondas de las bandas RGN. Fuente: (mapir, 2022)

La aplicación DJI GS Pro fue la utilizada al momento de definir la ubicación del área de estudio, ruta (polígono), velocidad y altura del vuelo (Figura 3.6), los cuales fueron constantes en todos los vuelos realizados, y están en función de la resolución del sistema sensor de la cámara espectral y el ángulo de orientación de las líneas de vuelo y de la superficie que representa el tamaño del pixel. En la configuración de la cámara, la cual se realiza de forma separada y considerando los parámetros establecidos en el VANT, los parámetros a configurar fueron: tamaño de la imagen (4000 x 3000 px); modo de toma única (no secuencial); obturador automático; toma de las imágenes; metadatos de la antena GNSS en cada una de las imágenes; y formato de las imágenes RAW. En la Tabla 3.2 se muestran las características de la cámara.



**Figura 3.6.** Captura del vuelo desde la aplicación DJI GS Pro.

**Tabla 3.2.** 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 ( <i>Ground Sample Distance</i> )	5.5 cm/px a 120 m
Sensor	Sony ExmorR IMX117 12MP (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 ,1 hr, 2 hrs, 6 hrs, 12 hrs y 24 hrs

Con la ayuda de 4 vuelos experimentales (Tabla 3.3) realizados antes de empezar con el monitoreo de tomate, se determinó el tamaño de píxel entre 1 y 2 cm para poder realizar un buen análisis espectral-

estadístico de los índices de vegetación. Esto por dos razones importantes; una de ellas es si se obtiene un píxel más pequeño con mayor resolución espacial, la cantidad de datos e información es mayor y el procesamiento toma una mayor cantidad de tiempo. Además, implica un mayor tiempo de vuelo ya que se tendría que bajar la altura de los vuelos; al contrario, si se aumenta la altura del vuelo se podría sobreestimar el área de la planta e inducir errores en los índices y en su análisis. Considerando lo anterior, se establecieron los parámetros de vuelo y cámara de forma individual, esto al ser independientes entre sí.

**Tabla 3.3.** Características de los vuelos realizados previamente de comenzar con los monitoreos.

Número de vuelo	Fecha	Altura (m)	Velocidad (m/s)	Solapamiento transversal (%)	Solapamiento longitudinal (%)	GSD (cm)
1	10/03/21	40	4.7	91.44	57.8	~1.83
2	08/04/21	40	4.7	82.88	57.8	~1.83
3	02/05/21	40	4.7	82.88	57.8	~1.83
4	06/10/21	50	-	-	-	~2.29

### 3.4.1 Calibración de las imágenes

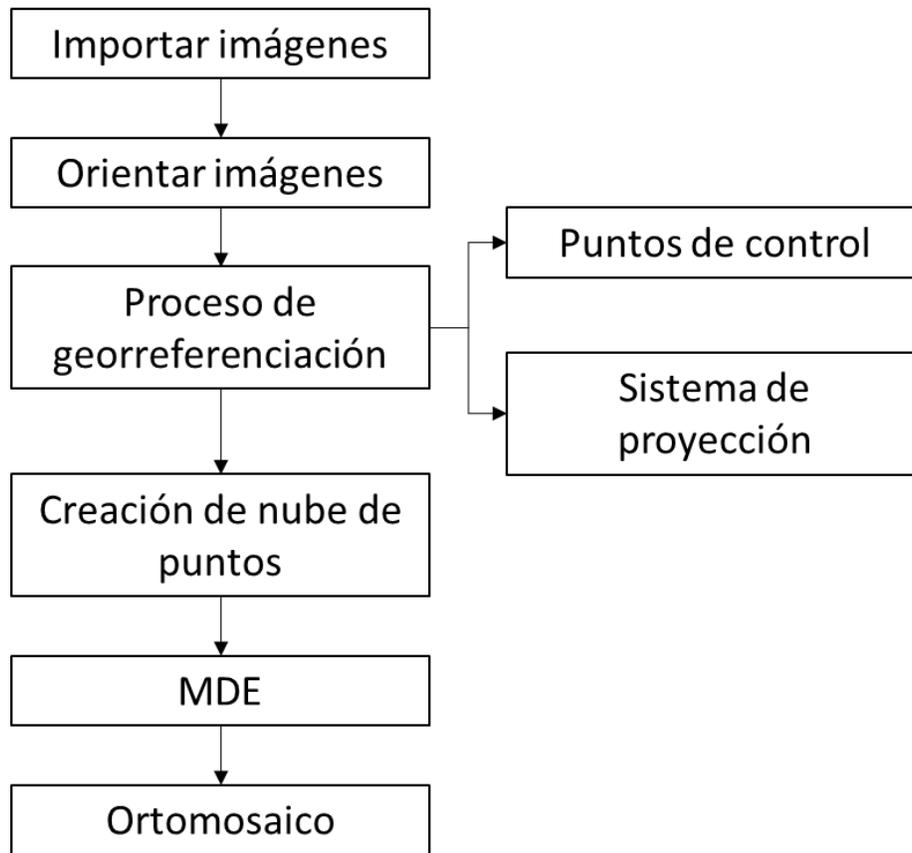
La calibración de la cámara se realizó una vez establecidos los parámetros anteriormente mencionados. Esta calibración realizada consiste en la captura de un par de imágenes antes de realizar el vuelo del objetivo terrestre (*Ground Target*) (Figura 3.7), y post-procesarlas en el software MCC (*MAPIR Camera Control*). MCC es un software de código abierto el cual realiza la calibración utilizando el método de la línea empírica (Smith & Milton, 1999) para convertir la radiación registrada por el sensor de la cámara en reflectancia a través de un análisis de regresión utilizando valores de reflectancia conocidos. Por lo que, en campo, antes de comenzar con los vuelos, se tomó una captura al objetivo terrestre a una altura aproximadamente de 1.2 m sobre la superficie. Después de obtenidas estas imágenes, se ancla la cámara a la base colocada con anterioridad en el VANT. Una vez realizado este proceso, se continuó con el vuelo en el área de estudio. Una vez finalizado el vuelo las imágenes son descargadas en una computadora y post-procesadas en el software anteriormente mencionado. Finalmente se realizó la calibración de cada una de las imágenes con la ayuda del software de MCC. El software consiste en importar las imágenes RAW al procesamiento y así transformar las imágenes RAW a formato TIF, posteriormente se realiza la calibración con la ayuda de las imágenes que se tomaron del objetivo terrestre.



**Figura 3.7.** Objetivo terrestre utilizado.

### **3.5 Generación de ortomosaicos**

El procesamiento y generación de ortomosaicos se llevó a cabo en AgisoftMetashape profesional versión 1.5.1, un software de estructura a partir del movimiento (SfM) y fotogrametría. El flujo de trabajo se puede dividir en seis fases (Figura 3.8): (1) orientación cámara en la que se estima cada posición de cámara y orientación externa, construyendo un modelo de nube de puntos dispersos; (2) configuración del sistema de coordenadas geográficas a métricas; (3) reconstrucción de la superficie a través de la generación de una nube de puntos densa basada en las posiciones estimadas de la cámara; (4) modelo digital de elevación (MDE) mediante interpolación de la nube de puntos densificada; y (5) ortomosaico basado en la orientación externa de la imagen y la superficie DEM.



**Figura 3.8.** Flujo de trabajo en AgisoftMetashape.

En primer lugar, la orientación de la cámara realiza una rápida referenciación de las imágenes haciendo coincidir puntos distintos (puntos clave) en imágenes adyacentes (Steiner *et al.*, 2015). Se ha permitido una precisión establecida como baja/mediana, un número máximo de 40,000 puntos clave por foto y 10,000 puntos de enlace por foto (Tabla 3.4). Obteniendo como resultado de esta etapa una nube de puntos dispersos estimando las posiciones de la cámara y los parámetros de calibración de la cámara utilizando los puntos de enlace

**Tabla 3.4.** Ajustes de los parámetros en el flujo de trabajo de SfM.

Flujo de trabajo de SfM	Parámetros	Ajustes
Orientación de la cámara	Precisión	Baja/Media
	Pre-selección genérica	No
	Pre-selección de referencia	Si
	Puntos clave por foto	40,000
	Puntos de enlace por foto	10,000
	Adaptativo Ajuste del modelo de cámara	Si

Nube de puntos densa	Calidad	Alta
	Filtrado de profundidad	Agresivo
MDE	Datos fuente	Nube de puntos densa
	Interpolación	Habilitada
Ortomosaico	Superficie	MDE
	Modo de mezcla	Mosaico
	Permitir la corrección de color	No
	Realizar el relleno de agujeros	Si

El siguiente paso es la configuración de las coordenadas de los puntos de control sobre el suelo (GCP por sus siglas en inglés) en todas las imágenes. Cada GCP debe estar marcado, etiquetado y georreferenciado. AgisoftMetashape ayuda al usuario a identificar automáticamente los GCP que podrían alinearse utilizando la nube de puntos dispersos. Sin embargo, todos los GCP se verificaron y reposicionaron con precisión. Además, se definieron los proyectos de cada vuelo con la proyección del proyecto (UTM Zona 13).

La siguiente etapa consistió en la generación de la nube de puntos densa. La calidad del cálculo se estableció en Alta (Tabla 3.4), esto significa que las imágenes se reducen en un factor de 4 antes del procesamiento. Además, la opción Extra Alta solo es adecuada para imágenes muy nítidas desde distancias cercanas y no para imágenes aéreas (Steiner *et al.*, 2015). La resolución resultante fue de aproximadamente de 1.83 cm/pix para imágenes desde una altura de 40 m.

Finalmente, se generó el DEM y posteriormente el ortomosaico. Este último se exportó utilizando la función "Exportar Ortomosaico" en formato ".TIFF". El tamaño de píxel para el archivo de salida se usó según el valor recomendado, el cual depende de la configuración de calidad durante la generación de la nube de puntos densa. Los archivos TIFF tienen un tamaño de archivo entre 3.44 y 1.82 GB dependiendo de su resolución y el área de cobertura.

### 3.6 Álgebra de bandas

En la estimación de los índices espectrales que se encuentran en las longitudes de onda en las cuales fueron adquiridas las imágenes espectrales (Tabla 3.5). En los antecedentes se identificó que estos índices son los que han dado mejores resultados en los últimos años en el análisis de PR en cultivos agrícolas, principalmente en hortalizas.

**Tabla 3.5.** Índices aplicados en hortalizas según la literatura.

Índice de vegetación	Ecuación	Referencia
Ratio Vegetation Index (RVI)	$RVI = \frac{R_{NIR}}{R_{RED}}$	(Birth & McVey, 1968)
Green Vegetation Index (GVI)	$GVI = \frac{R_{NIR}}{R_{GREEN}}$	(Birth & McVey, 1968)

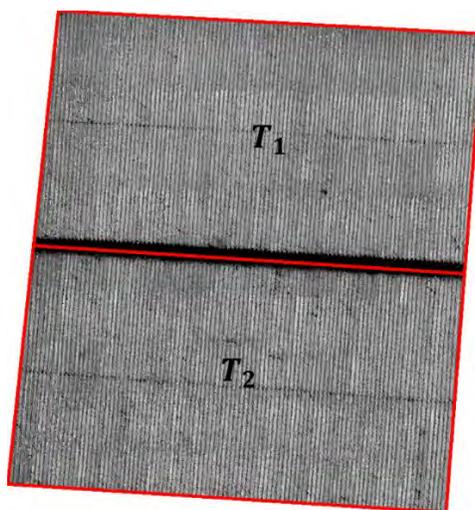
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	(Rouse <i>et al.</i> , 1974)
Infrared Percentage Vegetation Index (IPVI)	$IPVI = \frac{R_{NIR}}{R_{NIR} + R_{RED}}$	(Crippen, 1990)
Non-Linear Index (NLI)	$NLI = \frac{R_{NIR}^2 - R_{RED}}{R_{NIR}^2 + R_{RED}}$	(Goel & Qin, 1994)
Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = \frac{R_{NIR} - R_{GREEN}}{R_{NIR} + R_{GREEN}}$	(Gitelson & Merzlyak, 1997)
Optimized Soil-Adjusted Vegetation Index (OSAVI)	$OSAVI = \frac{1.16 * (R_{NIR} - R_{RED})}{R_{NIR} + R_{RED} + 0.16}$	(Haboudane <i>et al.</i> , 2002)

---

Una vez que se obtuvo el ortomosaico correspondiente se procedió a realizar el algebra de bandas con los IV propuestos; este proceso se realizó desde AgisoftMetashape. Este software nos ayuda a trabajar con las bandas de maneta individual, al momento de realizar el algebra de bandas se detectan 3 canales o cañones en donde se encuentran las bandas del rojo, verde y azul las cuales corresponden a una imagen común. En nuestro caso se utilizó banda roja (canal rojo), verde (canal verde) y la infrarroja cercano (canal azul).

## 4.2 Análisis temporal y estadístico

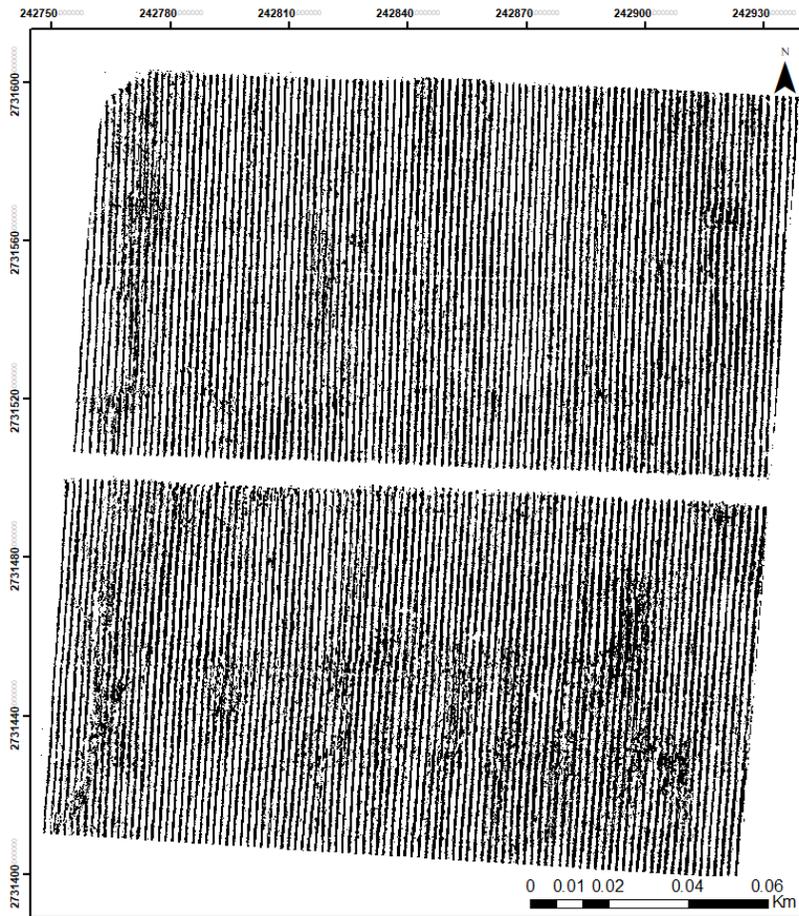
El presente estudio se realizó tomando en cuenta dos áreas, las cuales consisten en la tabla 1 ( $T_1$ ) y tabla 2 ( $T_2$ ) como se muestra en la Figura 3.9. Para la delimitación de cada tabla, se consideró tener áreas de cultivo aproximadamente iguales de ambas tablas, abarcando como polígono final un área de 1.73 y 1.77 hectáreas, respectivamente. Obteniendo así el polígono que ayudará en la extracción de información estadística (promedio y desviación estándar). El corte realizado en las imágenes con cada IV se realizó en ENVI versión 5.3.



**Figura 3.9.** Área de estudio, delimitada en  $T_1$  y  $T_2$ .

Se realizaron un total de siete vuelos sobre el área de estudio. Con la intención de evitar errores en la extracción de datos estadísticos de los índices, errores provocados principalmente por desplazamientos de la cámara y/o huecos resultantes del procesamiento fotogramétrico, se hizo uso de una máscara binaria única para cada fecha.

Asimismo, se realizó un segundo análisis, en donde una vez finalizado el monitoreo se reestableció el área de estudio definiendo una nueva máscara binaria para cada vuelo, en donde solo se delimito el área de la planta, la cual se realizó con la ayuda de una clasificación supervisada (Figura 3.10) realizada en el software ENVI. Esto último con el fin de obtener un análisis en donde no afectara el ruido provocado por los pixeles del suelo y la sombra.



**Figura 3.10.** Máscara binaria de la  $T_1$  y  $T_2$  considerando solo el área que representa planta. Vuelo de la fecha 10/11/21.

Los datos obtenidos para ambos procesos se pasaron posteriormente a Excel para poder manipular los datos con mayor facilidad. Además, con la ayuda del software Statgraphics se realizó el ANOVA para cada uno de los índices de vegetación (Tabla 3.6). En este análisis se estableció como valor dependiente la media por cada IV y como factores las fechas de cada vuelo y las tablas que corresponden a cada media.

En donde podemos estimar estadísticamente si existe una diferencia estadística entre tablas, tanto por fechas como por el tipo de índice.

**Tabla 3.6.** Fórmulas para el ANOVA (multivariable).

Fuente de variación	Suma de cuadrados	Grados de libertad	Media de cuadrados	Razón-F
Fecha	$SSA = \sum_{i=1}^a n_i (\bar{y}_{i.} - \bar{y}_{..})^2$	$a - 1$	$MSA = \frac{SSA}{(a - 1)}$	$\frac{MSA}{MSE}$
Tipo de índice	$SSB = \sum_{j=1}^b n_j (\bar{y}_{.j} - \bar{y}_{..})^2$	$b - 1$	$MSB = \frac{SSB}{(b - 1)}$	$\frac{MSB}{MSE}$
Error	$SSE = SST - SSA - SSB$	$(a - 1)(b - 1)$	$MSE = \frac{SSE}{(a - 1)(b - 1)}$	
Total	$SST = \sum_{i=1}^a \sum_{t=i}^n (\bar{y}_{ij} - \bar{y}_{..})^2$	$N - 1$		

## 4. Resultados y discusiones

### 4.1 Imágenes espectrales

A partir del plan de vuelo se obtuvieron las imágenes con la cámara espectral, debido a que esta trabaja de manera independiente al VANT. Por lo tanto, se realizaron 4 vuelos diferentes en donde se modificaba la velocidad, altura de vuelo, y los traslapes longitudinal y transversal entre imágenes. En función de los parámetros establecidos en la aplicación de vuelo con la cámara RGB que posee el VANT de fábrica, se determinaron los parámetros de configuración de la cámara espectral MAPIR. Estos vuelos se llevaron a cabo con la finalidad de obtener imágenes con un tamaño de pixel igual o menor a 2 cm. Las Tablas 4.1 y 4.2 muestran los parámetros de la configuración de vuelo y la cámara óptimo para lograr la resolución establecida anteriormente:

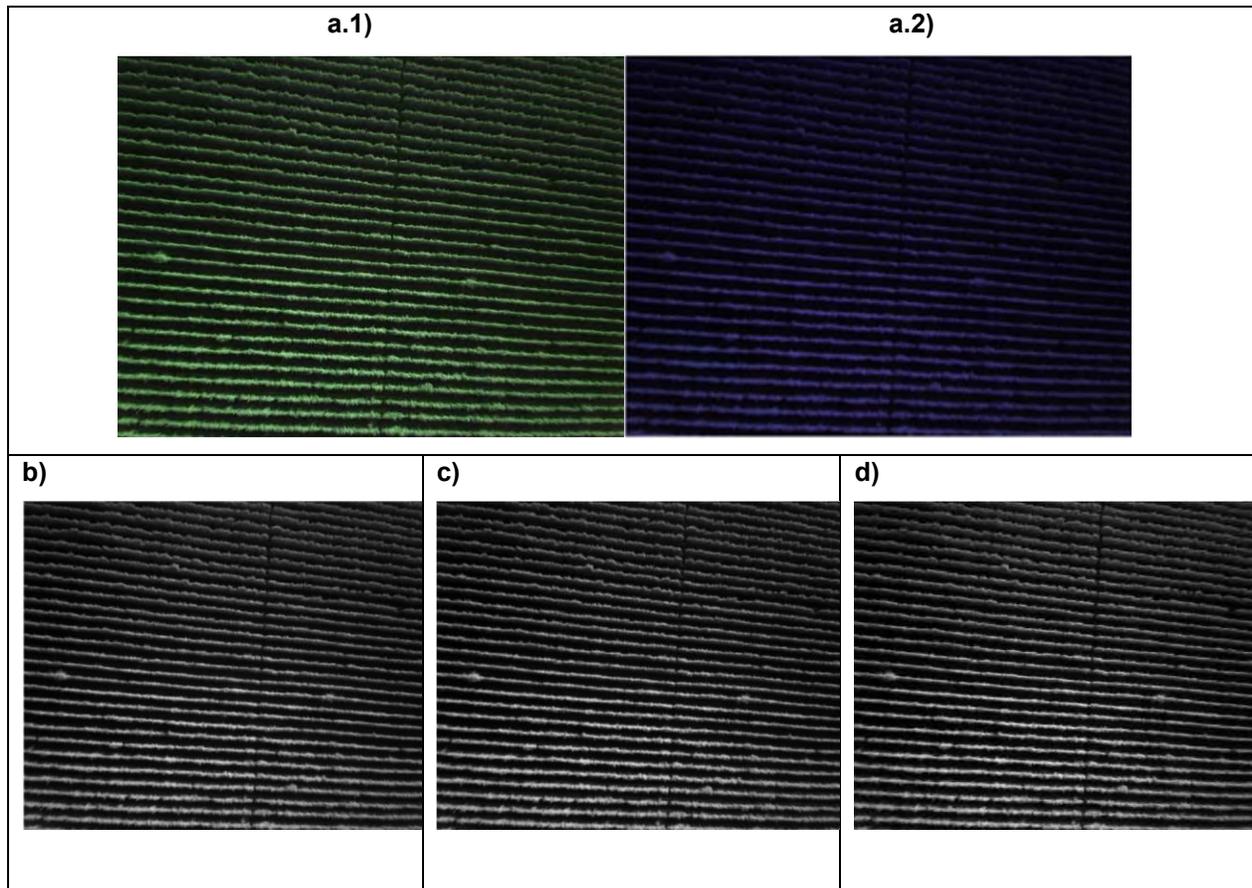
**Tabla 4.1.** Configuración de los parámetros de los vuelos realizados.

Parámetros del vuelo	
Velocidad	14.1 m/s
Altura	40 m
Solapamiento transversal	80 %
Solapamiento longitudinal	64 %

**Tabla 4.2.** Configuración de los parámetros de la cámara de los vuelos realizados.

<b>Parámetros de la cámara</b>	
Tiempo de Captura	1 seg
Tamaño de la imagen	12 Mpx
Solapamiento Transversal	92.8%
Solapamiento Longitudinal	62%
GSD ( <i>Ground Sample Distance</i> )	1.83 cm

Una vez establecidos los parámetros de vuelo y de la cámara, se inició con el monitoreo de los cultivos de tomate. La Figura 4.1 muestra un ejemplo de las imágenes aéreas obtenidas del cultivo en las bandas del rojo (b), verde (c) e infrarrojo cercano (d) utilizando los parámetros del plan de vuelo que se estipularon en la metodología. Asimismo, se muestra la imagen corregida radiométricamente (Figura 4.1, a.2)



**Figura 4.1.** a.1) Imagen procesada, a.2) Imagen corregida radiométricamente, b) banda roja de la imagen, c) banda verde de la imagen y d) banda infrarroja cercana de la imagen.

## 4.2 Generación de ortomosaicos

Los ortomosaicos se realizaron mediante el procesamiento fotogramétrico digital. En la Figura 4.2 se pueden observar los 7 vuelos realizados en el monitoreo y como ejemplo de forma más visible se muestra el resultado del vuelo 4 (Figura 4.3).

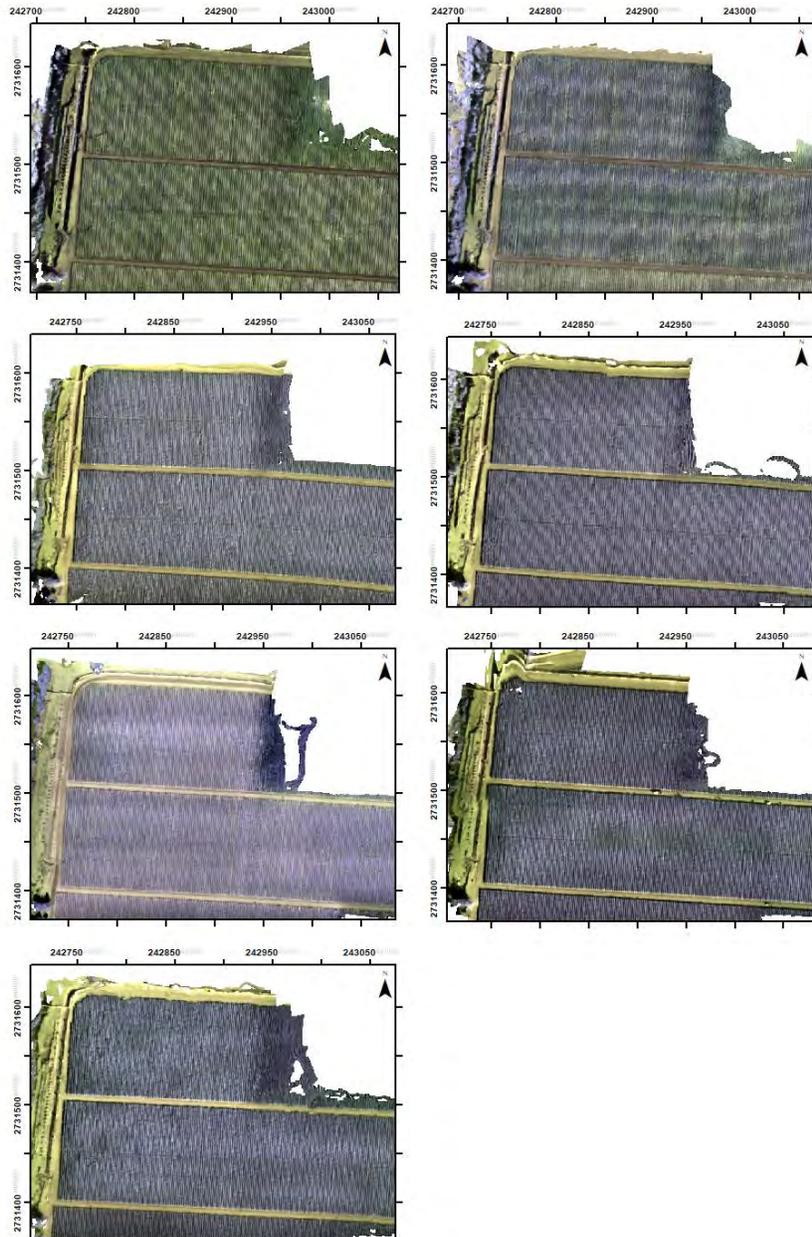


Figura 4.2. Ortomosaicos obtenidos en todos los vuelos realizados.



**Figura 4.3.** Ortomosaico obtenido del vuelo 4 de la fecha 21/11/21.

Asimismo, en la Tabla 4.3 se indican el total de vuelos realizados en su respectiva fecha de vuelo con información recolectada en el momento de realizarlos. En la Tabla 4.4 se muestran los intervalos de días que hay entre vuelos. Es necesario indicar que el primer vuelo se realizó cuando las plantas tenían más de 15 días después de ser trasplantadas del invernadero al campo abierto.

**Tabla 4.3.** Bitácora de los vuelos realizados.

Vuelo	Fecha	Hora	Condición climática	Observación de la planta
V1	15/10/2021	8:00 AM	Soleado y cielo con poca nubosidad	-
V2	24/10/2021	8:00 AM	Soleado y cielo con poca nubosidad	-
V3	10/11/2021	8:00 AM	Despejado, sin presencia de nubes	Empieza a tener tomates (fruto) y aun con flores.
V4	21/11/2021	7:30 AM	Día soleado, sin corrientes de aire	Las plantas de la tabla 2 se observan con más tomates rojos.

V5	03/12/2021	11:15 AM	Día soleado, sin nubes	Plantas con tomates maduros y con tomates verdes y flores (aun), empiezan con la cosecha.
V6	18/12/2021	8:30 AM	Cielo despejado y soleado	Existe una diferencia entre tablas, son más altas las plantas de la tabla 2 con respecto la tabla 1. Aún tienen flor.
V7	23/01/2022	9:00 AM	Día con más nubosidad	La planta aun cuenta con fruto y flor.

**Tabla 4.4.** Intervalos de tiempo entre vuelos.

Vuelos	Intervalo de tiempo (Días)
V1-V2	9
V2-V3	17
V3-V4	11
V4-V5	12
V5-V6	15
V6-V7	26

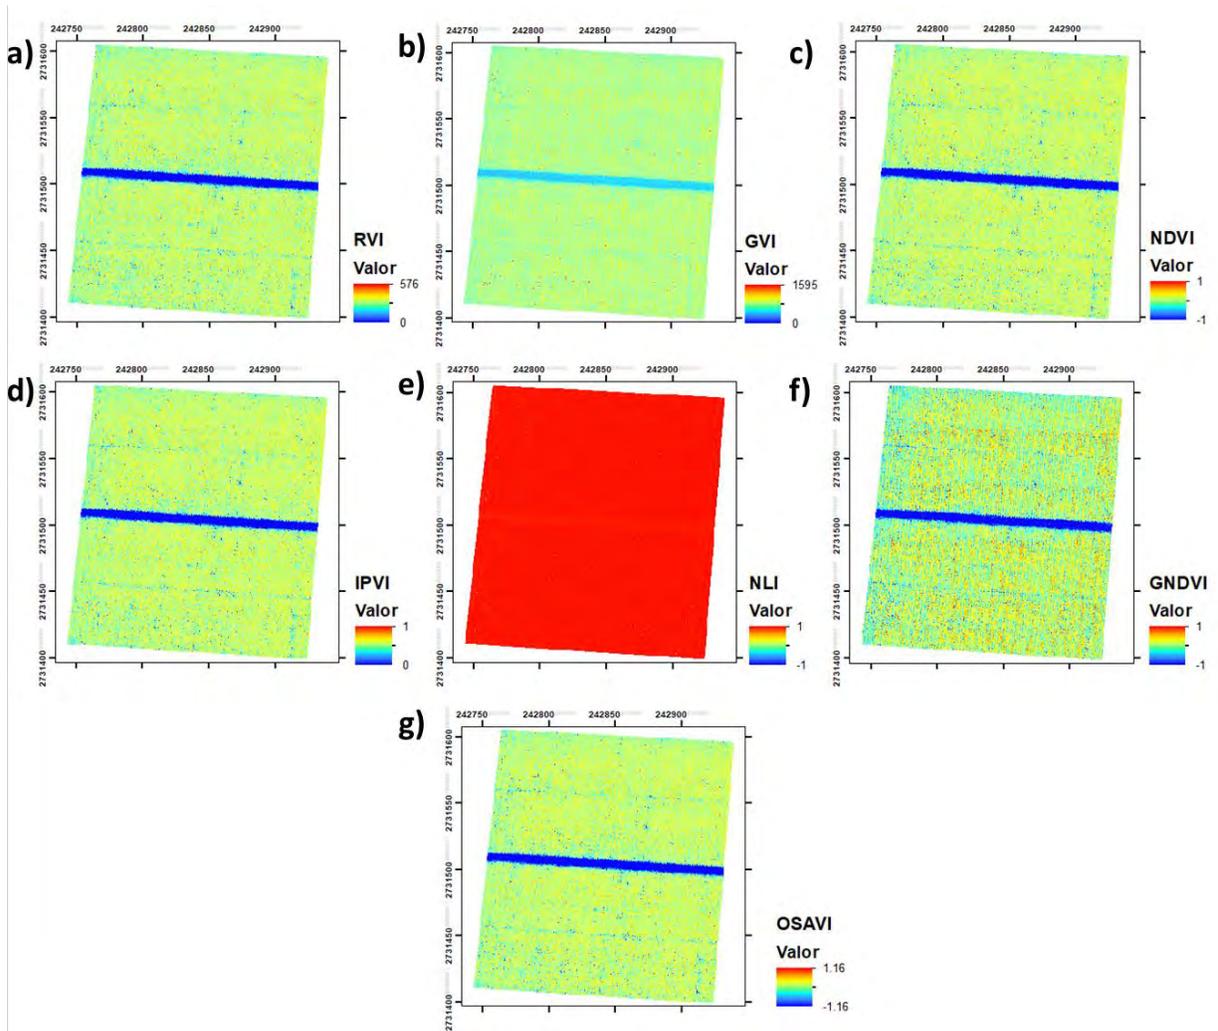
### 4.3 Generación y análisis de los IV

Después, se obtuvieron los IV de cada uno de los vuelos con la intención de poder estudiar el comportamiento de éstos a través del tiempo y su variación desde el punto de vista espacial. La Figura 4.4 muestra algunos índices a modo de ejemplo como resultado del V4. En el Anexo 7.1 se muestran todos los índices de cada vuelo realizado.

De manera consecutiva se realizó la extracción de los valores de los píxeles para cada uno de los vuelos y para cada uno de los IV para estimar la media ( $\bar{x}$ ) y la desviación estándar ( $S$ ). Los resultados se muestran de la Tabla 4.4 en los diferentes vuelos.

Cabe destacar que, en la extracción de los parámetros de la media y desviación estándar, los valores obtenidos en la gran mayoría de los índices son muy parecidos entre tablas ( $T_1 \approx T_2$ ) o incluso en algunos casos la  $T_1$  es superior a la  $T_2$ . Además, los histogramas obtenidos de los IV (Figura 4.4) se pueden observar un número considerable de píxeles que no representan el comportamiento de la clorofila en la planta. Como ejemplo, en la Figura 4.5a se observa un histograma del índice GNDVI del vuelo 7 (V7), en donde se observan dos picos, donde el más pequeño representa el ruido anteriormente descrito. En la Figura 4.5b se muestra el histograma del mismo vuelo, utilizando el mismo índice, con la diferencia de que solo se tomaron en cuenta píxeles que representan planta.

Lo anterior mencionado concuerda con estudios relacionados, donde hacen mención que los factores de la estructura del dosel, el suelo y la maleza en las imágenes espectrales interfieren en las características de reflexión del cultivo (Qiao *et al.*, 2020). Por lo que, los métodos de segmentación de imágenes resultan una solución para el ruido presente en los IV.



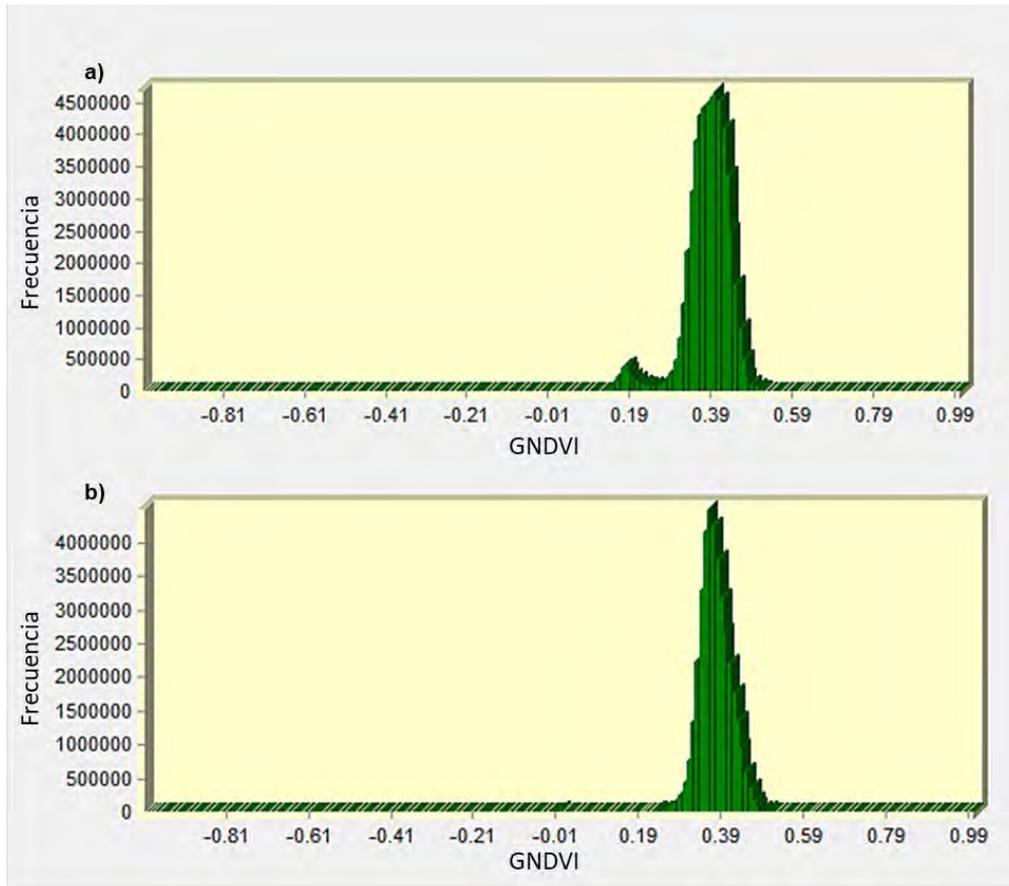
**Figura 4.4.** Resultados de los índices a) RVI, b) GVI, c) NDVI, d) IPVI, e) NLI, f) GNDVI y g) OSAVI del vuelo 4.

**Tabla 4.4.** Medias y Desviaciones estándar obtenidos de los índices en los siete vuelos realizados.

Número de vuelo	Fecha	Índices	$T_1$		$T_2$	
			$\bar{x}$	S	$\bar{x}$	S
1	15/10/2021	RVI	1.365	0.307	1.361	0.322
		GVI	1.067	0.394	1.063	0.416
		NDVI	0.148	0.072	0.146	0.076
		IPVI	0.574	0.036	0.573	0.038

		NLI	1.000	0.003	1.000	0.002
		GNDVI	0.023	0.097	0.020	0.101
		OSAVI	0.172	0.083	0.170	0.088
		RVI	1.499	0.211	1.485	0.203
		GVI	1.759	0.278	1.714	0.366
		NDVI	0.194	0.069	0.190	0.067
2	24/10/2021	IPVI	0.597	0.035	0.595	0.034
		NLI	1.000	0.005	1.000	0.002
		GNDVI	0.268	0.076	0.256	0.076
		OSAVI	0.225	0.080	0.220	0.078
		RVI	1.804	0.234	1.774	0.296
		GVI	2.156	0.767	2.114	1.029
		NDVI	0.284	0.046	0.275	0.061
3	10/11/2021	IPVI	0.642	0.023	0.637	0.030
		NLI	1.000	0.011	1.000	0.015
		GNDVI	0.362	0.057	0.352	0.065
		OSAVI	0.330	0.055	0.319	0.072
		RVI	1.867	0.190	1.880	0.187
		GVI	2.501	0.785	2.537	0.809
		NDVI	0.300	0.048	0.304	0.038
4	21/11/21	IPVI	0.650	0.024	0.652	0.019
		NLI	1.000	0.006	1.000	0.007
		GNDVI	0.424	0.054	0.430	0.050
		OSAVI	0.348	0.056	0.352	0.045
		RVI	1.520	0.399	1.500	0.344
		GVI	1.826	0.719	1.796	0.566
		NDVI	0.191	0.109	0.185	0.108
5	03/12/2021	IPVI	0.596	0.055	0.593	0.054
		NLI	1.000	0.001	1.000	0.001
		GNDVI	0.276	0.103	0.270	0.098
		OSAVI	0.222	0.127	0.215	0.125
		RVI	1.905	0.194	1.921	0.255
		GVI	2.536	0.923	2.499	1.223
		NDVI	0.309	0.046	0.312	0.051
6	18/12/2021	IPVI	0.655	0.023	0.656	0.025
		NLI	1.000	0.005	1.000	0.007
		GNDVI	0.428	0.064	0.420	0.071
		OSAVI	0.359	0.053	0.362	0.060
		RVI	1.830	0.164	1.791	0.185
		GVI	2.269	0.721	2.254	0.391
		NDVI	0.291	0.043	0.280	0.054
7	23/01/2022	IPVI	0.646	0.022	0.640	0.027

	NLI	1.000	0.006	1.000	0.005
	GNDVI	0.384	0.051	0.381	0.054
	OSAVI	0.338	0.050	0.325	0.062



**Figura 4.5.** Histogramas resultantes del índice GNDVI del V7 a) considerando toda la  $T_1$  y b) considerando solo el área de la planta en la  $T_1$ .

Por este motivo, se cambió la máscara binaria. Es necesario indicar que para todos los vuelos se generó una máscara única para extraer la información de las reflectancias, utilizar los modelos pertinentes para obtener los diversos índices y realizar el análisis solo en áreas donde existe planta. En otras palabras, el suelo y las sombras no se tomaron en cuenta durante el análisis estadístico. En la Tabla 4.5 se muestran los resultados en donde se enlistan los datos extraídos de las medias y desviaciones estándar de la  $T_1$  y  $T_2$  en cada vuelo.

**Tabla 4.5.** Medias y Desviaciones estándar de los índices utilizando la máscara binaria con la zona de interés (planta).

Número de vuelo	Fecha	Índices	$T_1$		$T_2$	
			$\bar{x}$	S	$\bar{x}$	S
1	15/10/2021	RVI	1.498	0.213	1.499	0.447
		GVI	1.037	0.351	1.023	0.558
		NDVI	0.196	0.056	0.196	0.056
		IPVI	0.598	0.028	0.598	0.028
		NLI	1.000	0.007	1.000	0.006
		GNDVI	0.007	0.105	0.001	0.101
		OSAVI	0.227	0.066	0.227	0.065
2	24/10/2021	RVI	1.657	0.183	1.645	0.169
		GVI	1.811	0.308	1.762	0.533
		NDVI	0.244	0.051	0.241	0.049
		IPVI	0.622	0.025	0.620	0.025
		NLI	1.000	0.008	1.000	0.004
		GNDVI	0.280	0.080	0.268	0.077
		OSAVI	0.283	0.059	0.279	0.057
3	10/11/2021	RVI	1.855	0.129	1.850	0.334
		GVI	2.077	0.748	2.078	1.036
		NDVI	0.298	0.029	0.297	0.030
		IPVI	0.649	0.015	0.649	0.015
		NLI	1.000	0.007	1.000	0.009
		GNDVI	0.347	0.047	0.347	0.047
		OSAVI	0.346	0.034	0.345	0.035
4	21/11/2021	RVI	1.902	0.164	1.906	0.206
		GVI	2.405	1.034	2.422	1.110
		NDVI	0.310	0.021	0.311	0.022
		IPVI	0.655	0.011	0.656	0.011
		NLI	1.000	0.008	1.000	0.009
		GNDVI	0.410	0.036	0.413	0.039
		OSAVI	0.360	0.027	0.361	0.027
5	03/12/2021	RVI	1.794	0.352	1.799	0.192
		GVI	2.026	0.552	2.037	0.545
		NDVI	0.281	0.050	0.282	0.050
		IPVI	0.640	0.025	0.641	0.025
		NLI	1.000	0.002	1.000	0.001
		GNDVI	0.333	0.064	0.335	0.064
		OSAVI	0.326	0.058	0.327	0.058
6	18/12/21	RVI	1.944	0.193	1.948	0.277
		GVI	2.400	1.287	2.376	1.649
		NDVI	0.319	0.028	0.320	0.029
		IPVI	0.660	0.014	0.660	0.015

		NLI	1.000	0.008	1.000	0.009
		GNDVI	0.406	0.056	0.401	0.059
		OSAVI	0.370	0.033	0.372	0.036
		RVI	1.866	0.128	1.874	0.111
		GVI	2.229	0.810	2.268	0.423
		NDVI	0.301	0.022	0.303	0.023
7	23/01/2022	IPVI	0.651	0.011	0.652	0.014
		NLI	1.000	0.007	1.000	0.015
		GNDVI	0.378	0.040	0.385	0.041
		OSAVI	0.350	0.026	0.352	0.027

Con la ayuda de un código programado en R (Anexo 7.2) se facilitó la aplicación de la máscara, y la obtención del promedio y desviación estándar de cada uno de los índices. Se hizo uso de las librerías *raster*, *rgdal* y *sp* para estas operaciones.

A continuación, se muestra un extracto como ejemplo del código utilizado para la extracción de información estadística con la aplicación de la máscara binaria de la Figura 3.10. En un inicio se cargan las librerías utilizadas y posteriormente se carga la máscara de la tabla, en donde se especifican que todos los valores de 0 representen NA.

```
library(sp)
library(raster)
library(rgdal)

PLANT_T1<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-
22\\T1_MASC230122_PLANT.rst")

PLANT_T1[PLANT_T1==0]<-NA
```

Posteriormente, se carga el índice (en este caso ya tenía la zona delimitada en la T1) y se multiplica por la máscara binaria. Una vez realizada esta multiplicación, calculamos la media y la desviación estándar.

```
#tabla1

rvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-
22\\T1_RVI_230122")

rvit1_230122_m<-(rvit1_230122*PLANT_T1)

prom<-(rvit1_230122.prom <- data.frame(rvit1_230122.mean=cellStats(rvit1_230122_m,
"mean")))

desv<-(rvit1_230122.desv <- data.frame(rvit1_230122.sd=cellStats(rvit1_230122_m,
"sd")))
```

## 4.4 Análisis estadísticos de los índices espectrales

Los índices se compararon mediante un análisis ANOVA, en donde se tiene como valor dependiente la media por cada IV y como factores (A) fechas de cada vuelo y (B) tablas que corresponden para cada valor de media. En la Tabla 4.6 se muestra el ejemplo de la tabla ANOVA obtenida para el índice NDVI, en los Anexo 7.3 se encuentran todas las tablas ANOVA. En la Tabla 4.7 se enlistaron los resultados de todos los análisis de varianza.

**Tabla 4.6.** Análisis ANOVA del índice NDVI.

Fuente	Suma de Cuadrados	Grados de libertad	Cuadrado Medio	Razón-F	Valor-P
Efectos principales					
A: Fecha	0.0237227	5	0.00474454	2746.19	0.000
B: Tabla	1.12E-08	1	1.12E-08	0.01	0.9389
Residuos	8.63841E-06	5	1.72768E-06		
Total (corregido)	0.0237314	11			

**Tabla 4.7.** Resultados de los Valores-P de los IV estudiado.

IV	Fecha	Tabla
RVI	0.0000 *	0.9588
GVI	0.0000 *	0.7188
NDVI	0.0000 *	0.9389
IPVI	0.0000 *	0.9075
NLI	0.2541	0.2744
GNDVI	0.0000 *	0.4821
OSAVI	0.0002 *	0.4087

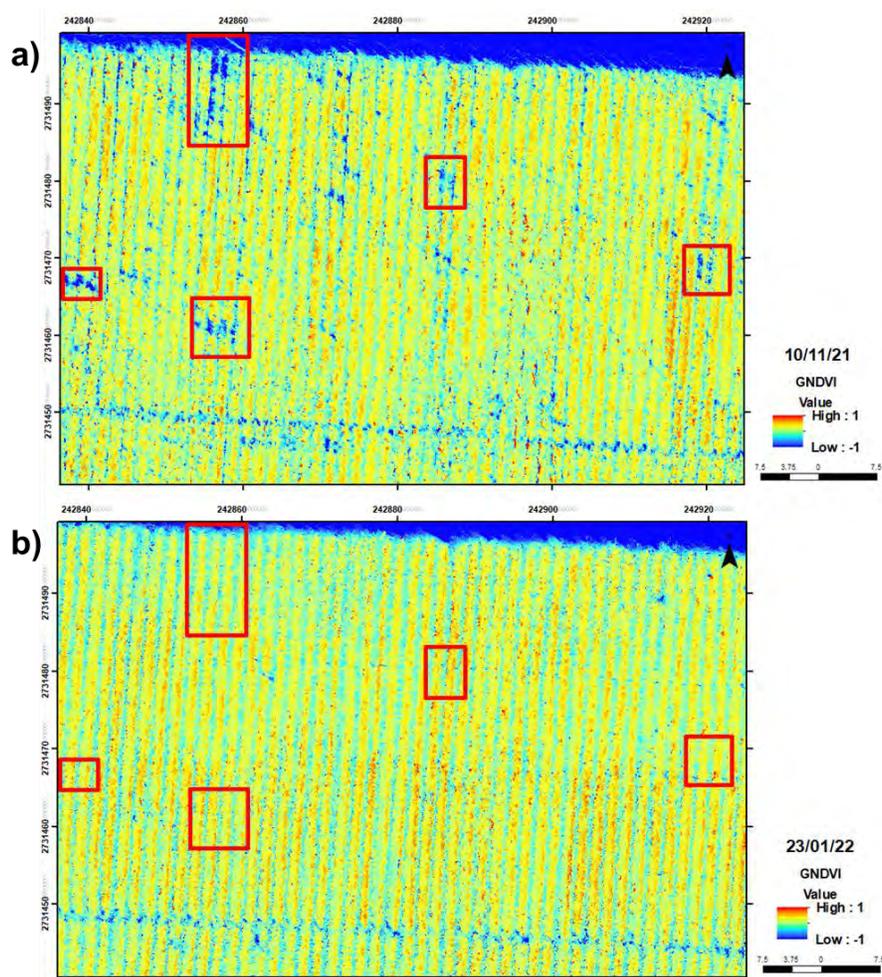
\*  $p < 0.05$

Los resultados obtenidos de las tablas ANOVA muestran que existe una diferencia significativa entre los valores obtenidos de los diversos índices en las fechas en las que se capturaron las imágenes, puesto que en la gran mayoría los casos el valor  $P < 0.05$  para cada vuelo. Por lo que los IV que corresponden a estos resultados serían el NDVI, IPVI, GNDVI, OSAVI, RVI y GVI.

En el análisis de varianza en el caso de las tablas podemos observar que, en todos los índices, incluso con la caracterización de las plantas obtenemos valores de  $P > 0.05$ . Considerando los resultados y antecedentes, estos resultados se pueden atribuir al diseño de experimentos, ya que como se ha comentado con anterioridad, no se sometió a ningún tipo de estrés. Aunque exista una diferencia en tratamientos entre tablas, al no presentar un déficit de nutrientes y/o agua, el comportamiento de la clorofila

no llegó a ser significativa. Resultado el cual presenta similitudes con los reportados en el estudio de Padilla *et al.* (2015), en donde el diseño de experimentos realizado consistió en suministrar cuatro tratamientos de nutrientes con distintas concentraciones de N, dos de estos tratamientos con un porcentaje de estrés por escasas de nutrientes (N1 y N2), y los otros dos tratamientos de maneta convencional (N3) y con excedente de N (N4). Obteniendo que los tratamientos N3 y N4 no existía una diferencia significativa en el estado de la clorofila en planta.

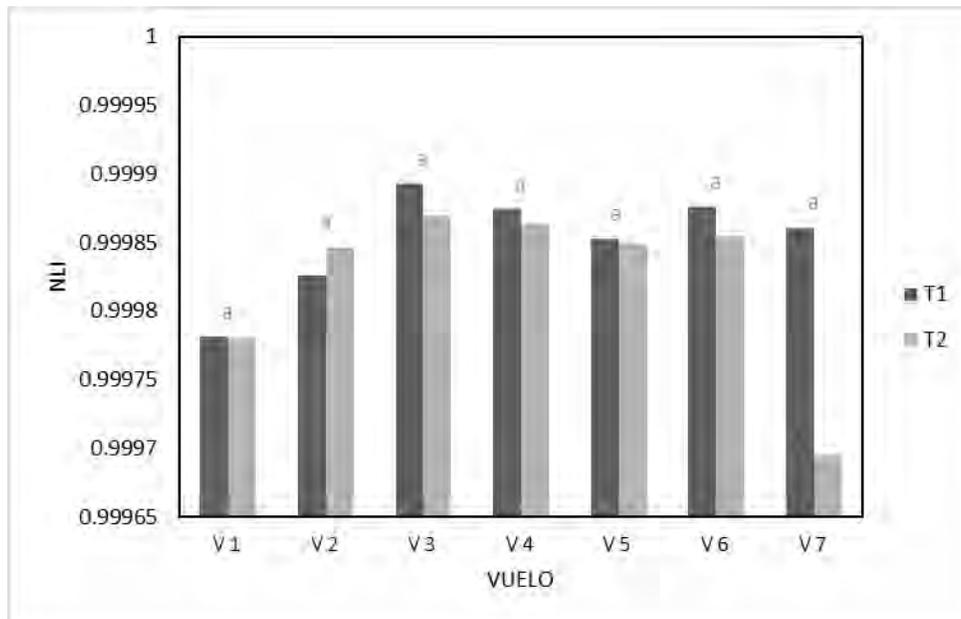
Por lo que podemos destacar que los índices IPVI, NDVI, GNDVI, OSAVI, GVI y RVI son de gran utilidad para el monitoreo de la clorofila en tomate cherri. En donde pueden ser utilizados para la detección de zonas afectadas (Figura 4.6) ya sea por estrés provocado por escasas de nutrientes y/o agua, presencia de plagas y enfermedades. Sin embargo, al igual que en otros estudios realizados en hortalizas, la etapa de madurez fue la que obtuvo mejor respuesta espectral para el monitoreo de clorofila.



**Figura 4.6.** Comparación del mismo índice GNDVI en diferentes vuelos a) V3 y b) V7. En donde se hace énfasis en zonas donde existió alguna perturbación de la planta y en fechas posteriores se corrigió.

### 4.4.1 NLI

Las medias de los índices obtenidos con anterioridad se graficaron con el fin de ver el comportamiento de los IV a lo largo de su crecimiento (Figuras 4.7 a 4.13). Se puede observar que la mayoría de los índices muestra un comportamiento similar entre sí, solamente el índice NLI (Figura 4.7) no muestra este comportamiento a lo largo de las fechas. En estas figuras (Figuras 4.8 a 4.13) se puede observar una reducción en los valores obtenidos en todos los índices durante el V5, posteriormente los valores del V6 vuelven a aumentas para continuar con el comportamiento esperado durante las diferentes etapas fenológicas, esto con relación al coeficiente del cultivo ( $K_c$ ); por lo que se decidió descartarlo en el ANOVA y evitar datos erróneos en el análisis estadístico. Los valores atípicos presentados en el V5 se pueden relacionar con la diferencia horaria en la que se realizó el vuelo, al existir un rango de tiempo considerable con respecto a los otros vuelos. Debido a que existe una relación con las mediciones espectroradiométricas dependiendo de las condiciones climáticas como por ejemplo la temperatura y el ángulo solar (Cabrera-Bosquet *et al.*, 2011).

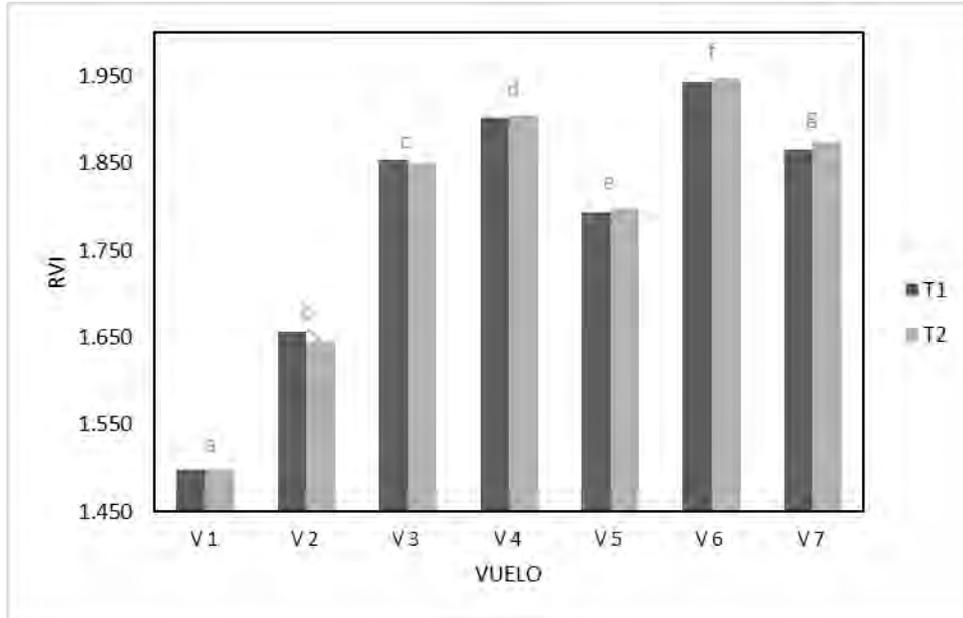


**Figura 4.7.** Graficas del comportamiento en cada vuelo del NLI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

### 4.4.2 RVI

El RVI se ha aplicado en estudios enfocados en el rendimiento de cultivos y biomasa (Sishodia *et al.*, 2020). De acuerdo con Padilla *et al.* (2015), el RVI responde al estrés por escasez de N en plantas de tomate. En el caso particular del presente estudio, este IV obtuvo un rango de 1.489 a 1.944 en la  $T_1$  y 1.499 a 1.948 en la  $T_2$  (Figura 4.8). Los valores obtenidos para el RVI son superiores si lo comparamos lo reportado por

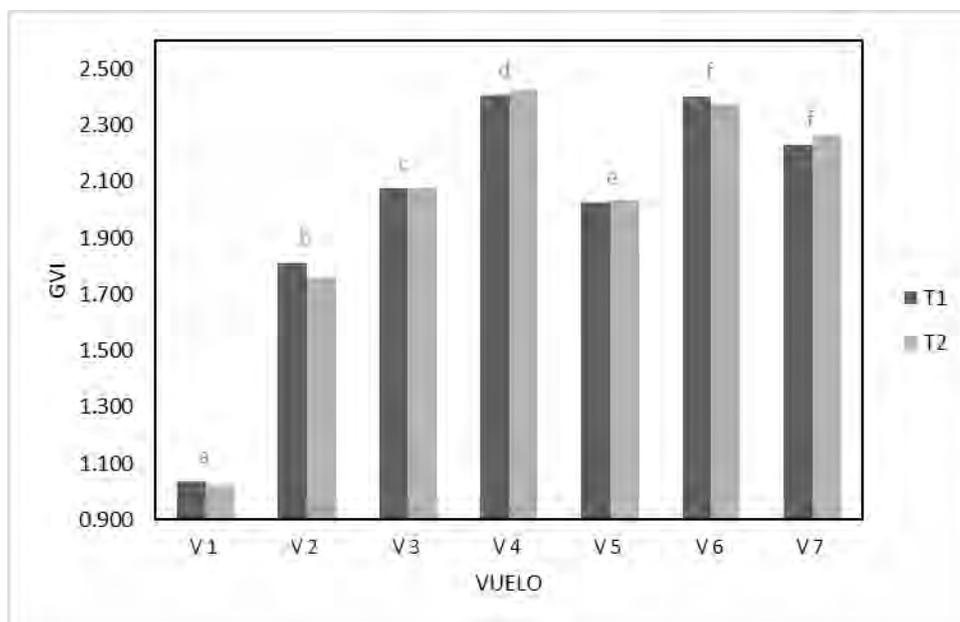
Padilla *et al.* (2015), quienes obtuvieron valores de RVI en un rango de 0.596 a 0.659 en plantas de tomate con concentraciones óptimas de N. Estos autores utilizaron un diseño de experimentos bajo condiciones de invernadero a fin de manipular el cultivo en función al N, por lo que esa pudiera ser la razón de la diferencia encontrada con este estudio.



**Figura 4.8.** Graficas del comportamiento en cada vuelo del RVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

### 4.4.3 GVI

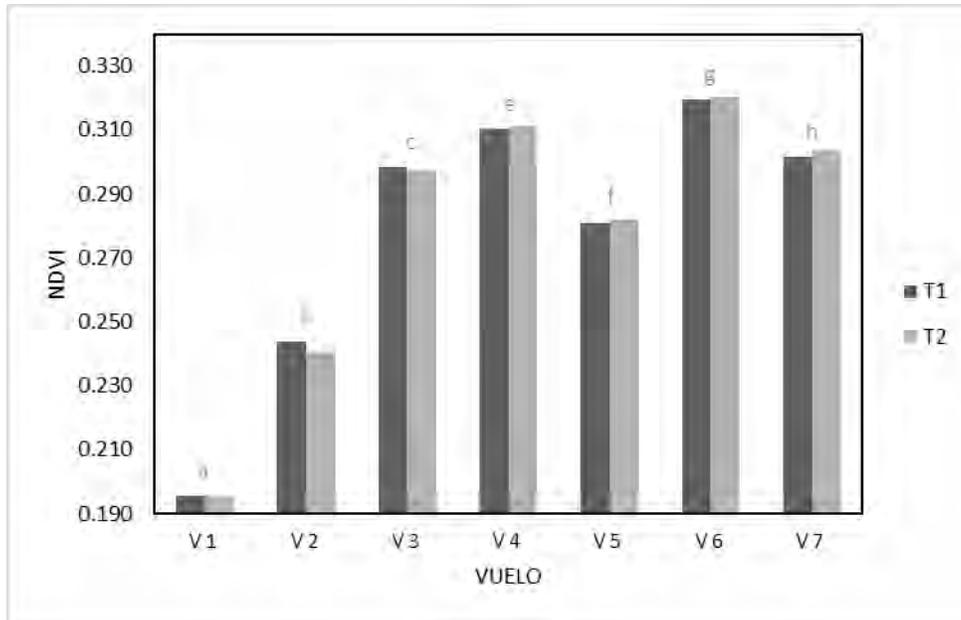
En el mismo estudio, Padilla *et al.* (2015) demuestran que el GVI también responde al estrés por la falta de N de la planta de tomates. Sin embargo, reportan que no responde al comportamiento de la clorofila en la última etapa del cultivo. En el caso del presente estudio, el GVI tuvo un rango de 1.037 a 2.405 en la  $T_1$  y 1.023 a 1.422 en la  $T_2$  (Figura 4.9). Este valor se encuentra por debajo de los valores que mencionan Padilla *et al.* (2015), quienes reportan un rango de 4.02 a 4.99 en condiciones óptimas. De igual forma, esta diferencia entre resultados se pudiera relacionar en que el experimento fue realizado en invernadero.



**Figura 4.9.** Graficas del comportamiento en cada vuelo del GVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

#### 4.4.4 NDVI

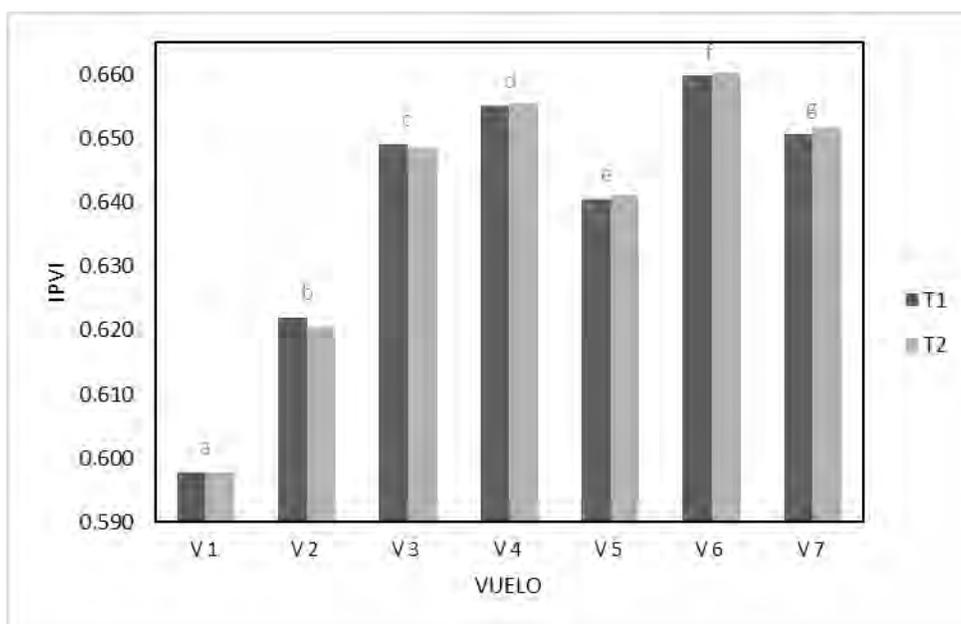
El NDVI ha sido reportado en numerosos estudios para la detección de clorofila, en donde podemos englobar las aplicaciones en estudios relacionados con biomasa, reproducción, rendimiento, enfermedades y humedad del suelo (Sishodia *et al.*, 2020). Además, este índice responde al estrés en plantas provocado por nutrientes y/o por estrés hídrico y ha mostrado una buena respuesta en la detección del estrés en los últimos años. (Padilla *et al.*, 2015; Kyratzis *et al.*, 2017; Mwinuka *et al.*, 2020; Qi *et al.*, 2021). En el presente estudio, el NDVI tuvo un rango de 0.196 a 0.319 en la  $T_1$  y 0.196 a 0.320 en la  $T_2$  (Figura 4.10). Los valores reportados en el presente estudio son similares a los reportados por Candiago *et al.* (2015) realizaron un único vuelo en un cultivo de tomate el cual se encontraba dividido en dos áreas (A y B), reportando un promedio de NDVI de 0.59 y 0.45 respectivamente. Sin embargo, Padilla *et al.* (2015) reportan un rango de 0.724 a 0.787 en un cultivo de tomate bajo condiciones de invernadero óptimas. Estos valores se encuentran por arriba del rango mencionado en el presente estudio. Mwinuka *et al.* (2020) en un estudio realizado en plantas de berenjena, reportan valores de NDVI oscilantes entre -0.3 a 0.62 en plantas en condiciones óptimas, donde mencionan que los valores de pixel negativos representan suelo desnudo. Kyratzis *et al.* (2017) obtuvo imágenes de cultivos de trigo con la ayuda de un VANT por dos años en donde el NDVI en el primer año tuvo un rango de 0.04668 a 0.55610 y el segundo un rango de 0.23476 a 0.56472. Estos valores son muy similares a los reportados en el presente estudio.



**Figura 4.10.** Graficas del comportamiento en cada vuelo del NDVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

#### 4.4.5 IPVI

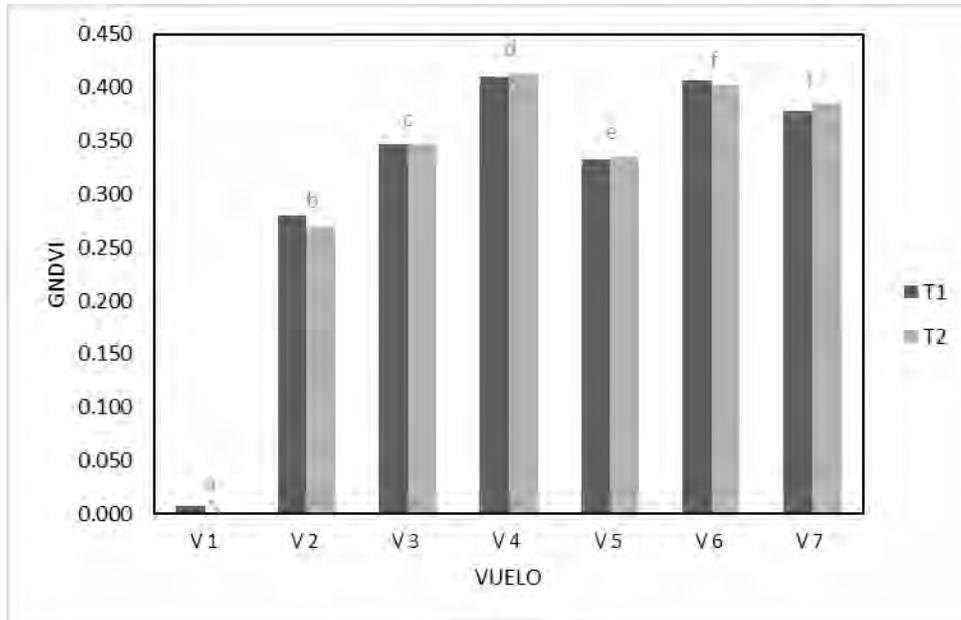
El IPVI es un índice el cual es linealmente equivalente al NDVI. Esta característica se ve reflejada en la Figura 4.11 en donde se muestra un comportamiento muy similar al obtenido en el NDVI. Sin embargo, este IV cuenta con un rango de 0 a 1 por lo que debe de dar resultados aún más sensibles (menor variación) que el NDVI. En el presente estudio el IPVI tuvo un rango de 0.598 a 0.660 en ambas tablas ( $T_1$  y  $T_2$ ). Por lo tanto, se puede decir que fue el IV que mostró una menor variación con todos los índices utilizado en el presente estudio. Ranjan *et al.* (2019) reporta en la etapa media de crecimiento de frijol un rango aproximadamente de 0.35 a 0.80, encontrando una similitud con los datos obtenidos en el presente estudio los cuales se encuentran dentro de este rango.



**Figura 4.11.** Graficas del comportamiento en cada vuelo del IPVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

#### 4.4.6 GNDVI

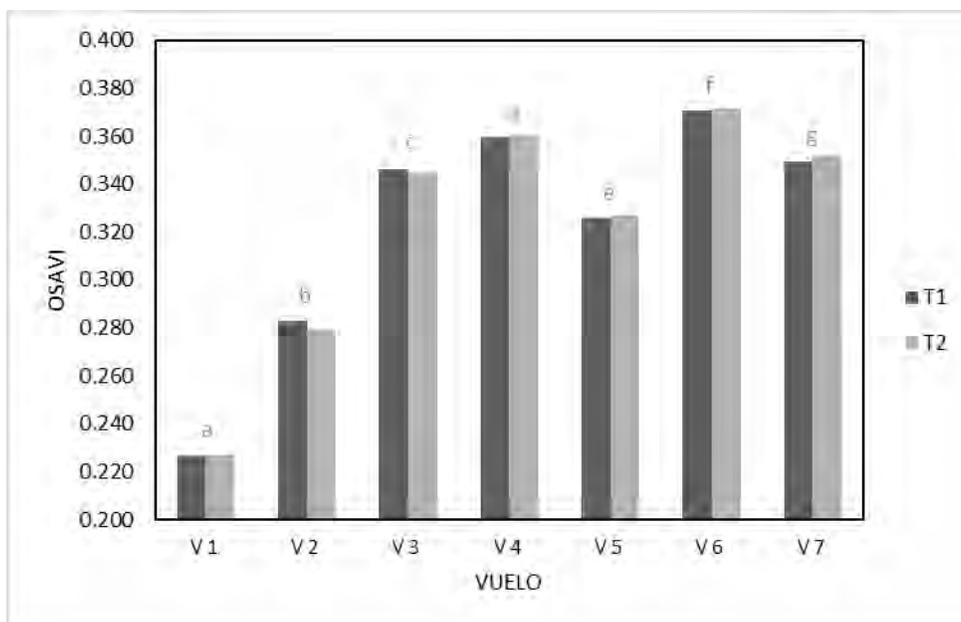
El GNDVI es otro de los IV que, según varios autores, han reportado que responde al estado de la clorofila en plantas que presentan estrés por escasas de nutrientes y/o hídrico, además de tener aplicaciones en estudios relacionados con rendimiento, biomasa y enfermedades (Sishodia *et al.*, 2020). En el presente estudio el GNDVI obtuvo un rango de 0.007 a 0.410 en la  $T_1$  y de 0.001 a 0.413 en la  $T_2$  (Figura 4.12). Los valores obtenidos en este índice son inferiores a los reportados por Padilla *et al.* (2015) en plantas de tomate, quienes reportan valores de GNDVI en el rango de 0.596 a 0.659. Candiago *et al.* (2015) realizaron un único vuelo en un cultivo de tomare el cual se encontraba dividido en dos áreas (A y B), el GNDVI tuvo una media de 0.22 y 0.17 respectivamente, encontrándose dentro del rango que se reporta en este estudio. Kyrtzis *et al.* (2017) reportaron el GNDVI en con un rango de 0.18053 a 0.29556, encontrándose dentro del rango obtenido en el presente estudio; sin embargo, este estudio fue realizado en plantas de trigo y pudiera existir diferencias en los IV por ser diferente especie. Considerando lo anterior, se logra observar un comportamiento en donde el IV presenta rangos por debajo a los índices anteriormente mencionados. Y para el caso particular del presente estudio, se considera un IV con poca sensibilidad a las variaciones.



**Figura 4.12.** Graficas del comportamiento en cada vuelo del GNDVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

#### 4.4.7 OSAVI

Por último, el OSAVI presenta una buena respuesta en la detección del estrés hídrico (Ihuoma & Madramootoo, 2019; Mwinuka *et al.*, 2020), además de demostrar que también ha ayudado en estudios relacionados con enfermedades, rendimiento, biomasa, absorción de N y humedad del suelo (Sishodia *et al.*, 2020). En el caso particular del presente estudio, el OSAVI tuvo un rango de 0.227 a 0.370 en la  $T_1$  y de 0.227 a 0.372 en la  $T_2$  (Figura 4.13). Por lo que se puede decir que es un índice que presentó poca variación, comparado con los índices anteriormente mencionados. Sin embargo, presenta la situación que limita al índice OSAVI, debido a que prácticamente los valores obtenidos en las dos tablas son iguales. El orden de los índices de mayor a menor variación en el presente estudio fue: IPVI>NDVI>OSAVI. Mwinuka *et al.* (2020) reportan un rango de valores del OSAVI en plantas de berenjena entre -0.32 a 0.6. Es importante hacer mención que los datos negativos encontrados en las imágenes representan pixeles de suelo, situación que en el presente estudio fue descartada. Ihuoma y Madramootoo (2019) hacen mención de que OSAVI fue uno de los índices más sensibles en la distinción del estrés hídrico en plantas de tomate (*Solanum lycopersicum L.*).



**Figura 4.13.** Graficas del comportamiento en cada vuelo del OSAVI. Diferentes letras minúsculas muestran diferencias significativas, Utilizando el método de diferencia mínima significativa (LSD) a  $P < 0.05$ , entre fechas.

## 5. Conclusiones

De acuerdo con el análisis estadístico, se determinó que los valores de píxel del suelo y sombras causan ruido en la estimación de los diferentes índices espectrales de vegetación, por lo que se realizó un cambio en la metodología en donde se utilizó una máscara binaria que representara únicamente pixeles de planta para obtener datos más precisos.

Los índices RVI, GVI, NDVI, IPVI, GNDVI y OSAVI tuvieron un comportamiento exponencial a través del tiempo, el cual era el esperado de acuerdo con lo reportado en otros estudios. Utilizando el análisis de varianza se demostró que estos índices mostraron una diferencia significativa a lo largo del tiempo. Sin embargo, el índice que no mostró un comportamiento similar fue el NLI, el cual tampoco mostró una diferencia estadísticamente significativa entre fechas, por lo que podemos concluir que es el IV que menos representa a la clorofila en la planta.

Los IV no mostraron una diferencia significativa estadísticamente en el ANOVA entre las dos tablas. Sin embargo, en el 67% de los casos se reportan que los valores en los índices RVI, NDVI, IPVI y OSAVI fueron mayores en la  $T_2$  con respecto a la  $T_1$ . Lo cual nos indica que esta metodología planteada nos ayuda a validar la eficiencia de los agro-insumos.

Además de que el IPVI, NDVI y OSAVI mostraron ser los índices con menor variación en la respuesta del comportamiento de la clorofila. Por otro lado, los índices RVI, GVI, NDVI, IPVI, GNDVI y OSAVI mostraron que pueden ser de gran ayuda para el monitoreo del cultivo en campo; como es el caso de la detección de zonas puntuales con alguna afectación ya sea nutricional o enfermedad.

Por último, se concluye que la metodología desarrollada puede ser utilizada para ayudar al monitoreo de la clorofila como alerta temprana en los cultivos, y a su vez, que sirva como instrumento para el agricultor en la toma de decisiones sobre la mejora del cultivo. Esto debido a que durante los vuelos se pudo detectar un déficit de clorofila y huecos dentro de los cultivos. Aportando así, en la identificación de zonas con problemas de manera precisa donde el ojo humano no puede detectarlo a simple vista.

Se deja el campo abierto y trabajo a futuro para continuar con este tipo de estudios relacionados a la AP, además de la propuesta propia de trabajo a futuro. En primer lugar, se propone implementar otros índices que propone la literatura, los cuales respondan al estrés inducido, y hacen uso de bandas más específicas, como es el caso de los índices hiperespectrales. Además de desarrollar una propuesta de IV propia, producto de los resultados de los análisis estadísticos, ya sea multiespectral o hiperespectral.

De igual forma, se propone ampliar la base de datos con información del mismo tipo de cultivo, y robustecer así la parte estadística en la existencia de un cambio de sensibilidad en cada IV en las distintas etapas de crecimiento del cultivo.

Como punto final, este estudio al realizarse con cultivos e insumos pertenecientes a la empresa Tecnofersa, ambas partes resultamos beneficiadas con los resultados obtenidos. Representa ser un parteaguas para poder justificar la implementación de un diseño de experimentos en un futuro, en donde tengamos la opción de realizar una manipulación en las variables de forma controlada y poder demostrar más específicamente que índice responde mejor al estrés en diversos escenarios, ya sea por nutrientes, agua y/o enfermedades.

# 1. Referencias

- Alves Varella, C. A., Gleriani, J. M., & dos Santos, R. M. (2015). Precision Agriculture and Remote Sensing. *Sugarcane: Agricultural Production, Bioenergy and Ethanol*, 185–203. <https://doi.org/10.1016/B978-0-12-802239-9.00009-8>
- Amigo, J. M. (2020). Hyperspectral and multispectral imaging: setting the scene. *Data Handling in Science and Technology*, 32, 3–16. <https://doi.org/10.1016/B978-0-444-63977-6.00001-8>
- Balafoutis, A. T., Beck, B., Fountas, S., Tsiropoulos, Z., Vangeyte, J., van der Wal, T., Soto-Embodas, I., Gómez-Barbero, M., & Pedersen, S. M. (2017). *Smart Farming Technologies – Description, Taxonomy and Economic Impact*. [https://doi.org/10.1007/978-3-319-68715-5\\_2](https://doi.org/10.1007/978-3-319-68715-5_2)
- Bennett, D., & Armstrong, M. (2010). GIS Fundamentals. In *Manual of Geospatial Science and Technology, Second Edition*. <https://doi.org/10.1201/9781420087345-c27>
- Birth, G. S., & McVey, G. R. (1968). Measuring the Color of Growing Turf with a Reflectance Spectrophotometer 1. *Agronomy Journal*, 60(6), 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>
- Cabrera-Bosquet, L., Molero, G., Stellacci, A., Bort, J., Nogués, S., & Araus, J. (2011). NDVI as a potential tool for predicting biomass, plant nitrogen content and growth in wheat genotypes subjected to different water and nitrogen conditions. *Cereal Research Communications*, 39(1), 147–159. <https://doi.org/10.1556/CRC.39.2011.1.15>
- Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sensing*, 7(4), 4026–4047. <https://doi.org/10.3390/rs70404026>
- Chuvieco, E. (1995). *Fundamentos de teledetección espacial* (p. 224). Ediciones Rialp, S.A.
- CODESIN. (2021). *SINALOA EN NÚMEROS: Agricultura en Sinaloa al 2020*. <https://sinaloaennumeros.codesin.mx/wp-content/uploads/2021/06/Reporte-29-del-2021-de-Agricultura-en-sinaloa-2020.pdf>
- Crippen, R. E. (1990). Calculating the vegetation index faster. *Remote Sensing of Environment*, 34(1), 71–73. [https://doi.org/10.1016/0034-4257\(90\)90085-Z](https://doi.org/10.1016/0034-4257(90)90085-Z)
- Elvanidi, A., Katsoulas, N., Augoustaki, D., Loulou, I., & Kittas, C. (2018). Crop reflectance measurements for nitrogen deficiency detection in a soilless tomato crop. *Biosystems Engineering*, 176(2015), 1–11. <https://doi.org/10.1016/j.biosystemseng.2018.09.019>
- FAO. (2002). *World Agriculture: towards 2015/2030: Summary Report*. Food and Agriculture Organization of the United Nations (FAO). <http://www.fao.org/3/y3557e/y3557e.pdf>

- Frauenfelder, R. (2021). Remote Sensing in Geology. In *Encyclopedia of Geology* (2nd ed.). Elsevier Inc. <https://doi.org/10.1016/b978-0-08-102908-4.00170-3>
- Gianquinto, G., Orsini, F., Fecondini, M., Mezzetti, M., Sambo, P., & Bona, S. (2011). A methodological approach for defining spectral indices for assessing tomato nitrogen status and yield. *European Journal of Agronomy*, 35(3), 135–143. <https://doi.org/10.1016/j.eja.2011.05.005>
- Gitelson, A. A., & Merzlyak, M. N. (1997). Remote estimation of chlorophyll content in higher plant leaves. *International Journal of Remote Sensing*, 18(12), 2691–2697. <https://doi.org/10.1080/014311697217558>
- Goel, N. S., & Qin, W. (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: a computer simulation. *Remote Sensing Reviews*, 10(4), 309–347. <https://doi.org/10.1080/02757259409532252>
- Gómez, M. & B. (2006). *Sistemas de Información Geográfica y evaluación multicriterio en la ordenación del territorio*. [https://www.mendeley.com/catalogue/5ff22c07-27c4-3956-9a89-6897728470f7/?utm\\_source=desktop](https://www.mendeley.com/catalogue/5ff22c07-27c4-3956-9a89-6897728470f7/?utm_source=desktop)
- Gonzalez, R. C., & Woods, R. E. (2008). *Digital Image Processing Third Edition Pearson*.
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J., & Dextraze, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2–3), 416–426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)
- Ihuoma, S. O., & Madramootoo, C. A. (2019). Sensitivity of spectral vegetation indices for monitoring water stress in tomato plants. *Computers and Electronics in Agriculture*, 163(September 2018), 104860. <https://doi.org/10.1016/j.compag.2019.104860>
- Ihuoma, S. O., & Madramootoo, C. A. (2020). Narrow-band reflectance indices for mapping the combined effects of water and nitrogen stress in field grown tomato crops. *Biosystems Engineering*, 192, 133–143. <https://doi.org/10.1016/j.biosystemseng.2020.01.017>
- Kyrtzis, A. C., Skarlatos, D. P., Menexes, G. C., Vamvakousis, V. F., & Katsiotis, A. (2017). Assessment of vegetation indices derived by UAV imagery for durum wheat phenotyping under a water limited and heat stressed Mediterranean environment. *Frontiers in Plant Science*, 8(June), 1–14. <https://doi.org/10.3389/fpls.2017.01114>
- Lopez, L. (2017). Manual técnico del cultivo de tomate. In *Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria (inta)*. <http://www.mag.go.cr/bibliotecavirtual/F01-10921.pdf%0Ahttp://www.mag.go.cr/bibliotecavirtual/F01-10921.pdf%0Ahttp://repositorio.iica.int/bitstream/11324/3143/1/BVE17079148e.pdf%0Awww.inta.go>

cr%0Ahttp://repositorio.iica.int/bitstream/11324/3143/1/BVE1707

- Lu, J., Cheng, D., Geng, C., Zhang, Z., Xiang, Y., & Hu, T. (2021). Combining plant height, canopy coverage and vegetation index from UAV-based RGB images to estimate leaf nitrogen concentration of summer maize. *Biosystems Engineering*, 202, 42–54. <https://doi.org/10.1016/j.biosystemseng.2020.11.010>
- mapir. (2022). *Survey3W Camera - Red+Green+NIR (RGN, NDVI)*. <https://www.mapir.camera/collections/survey3/products/survey3w-camera-red-green-nir-rgn-ndvi>
- Mason, A., & Schmetz, J. (1992). Meteorological satellites. *International Journal of Remote Sensing*, 13(6–7), 1153–1172. <https://doi.org/10.1080/01431169208904185>
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358–371. <https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- Mwinuka, P. R., Mbilinyi, B. P., Mbungu, W. B., Mourice, S. K., Mahoo, H. F., & Schmitter, P. (2020). The feasibility of hand-held thermal and UAV-based multispectral imaging for canopy water status assessment and yield prediction of irrigated African eggplant (*Solanum aethopicum* L). *Agricultural Water Management*, xxxx, 106584. <https://doi.org/10.1016/j.agwat.2020.106584>
- Ocampo, M., & Santa Catarina, C. (2018). Agricultura de Precisión. *Oficina de Información Científica y Tecnológica Para El Congreso de La Union (INCyTU)*, 15.
- Padilla, F. M., Peña-Fleitas, M. T., Gallardo, M., & Thompson, R. B. (2015). Threshold values of canopy reflectance indices and chlorophyll meter readings for optimal nitrogen nutrition of tomato. *Annals of Applied Biology*, 166(2), 271–285. <https://doi.org/10.1111/aab.12181>
- Padilla, Francisco M., Farneselli, M., Gianquinto, G., Tei, F., & Thompson, R. B. (2020). Monitoring nitrogen status of vegetable crops and soils for optimal nitrogen management. *Agricultural Water Management*, 241(January), 106356. <https://doi.org/10.1016/j.agwat.2020.106356>
- Pantazi, X. E., Moshou, D., & Bochtis, D. (2020). Sensors in agriculture. *Intelligent Data Mining and Fusion Systems in Agriculture*, 1–15. <https://doi.org/10.1016/b978-0-12-814391-9.00001-7>
- Qi, H., Wu, Z., Zhang, L., Li, J., Zhou, J., Jun, Z., & Zhu, B. (2021). Monitoring of peanut leaves chlorophyll content based on drone-based multispectral image feature extraction. *Computers and Electronics in Agriculture*, 187(June), 106292. <https://doi.org/10.1016/j.compag.2021.106292>
- Qiao, L., Gao, D., Zhang, J., Li, M., Sun, H., & Ma, J. (2020). Dynamic influence elimination and chlorophyll content diagnosis of maize using UAV spectral imagery. *Remote Sensing*, 12(16). <https://doi.org/10.3390/RS12162650>
- Ranjan, R., Chandel, A. K., Khot, L. R., Bahlol, H. Y., Zhou, J., Boydston, R. A., & Miklas, P. N. (2019).

- Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. *Information Processing in Agriculture*, 6(4), 502–514. <https://doi.org/10.1016/j.inpa.2019.01.005>
- Rouse, J., Haas, R., Schell, J., & Deering, D. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351, 309.
- Sandwell, D. T. (2013). Physical principles of remote sensing: third edition. In *Geophysical Journal International* (Vol. 195, Issue 3). <https://doi.org/10.1093/gji/ggt314>
- Schlemmera, M., Gitelson, A., Schepersa, J., Ferguson, R., Peng, Y., Shanahana, J., & Rundquist, D. (2013). Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. *International Journal of Applied Earth Observation and Geoinformation*, 25(1), 47–54. <https://doi.org/10.1016/j.jag.2013.04.003>
- Schowengerdt, R. A. (2007). Remote sensing: Models and methods for image processing: Second edition. In *Remote Sensing: Models and Methods for Image Processing: Second Edition*. <https://doi.org/10.1016/C2009-0-21902-7>
- Shaver, T. M., Kruger, G. R., & Rudnick, D. R. (2017). Crop canopy sensor orientation for late season nitrogen determination in corn. *Journal of Plant Nutrition*, 40(15), 2217–2223. <https://doi.org/10.1080/01904167.2017.1346681>
- Sholarin, E. A., & Awange, J. L. (2015). Photogrammetry. *Environmental Science and Engineering (Subseries: Environmental Science)*, 9783319276496, 213–230. [https://doi.org/10.1007/978-3-319-27651-9\\_10](https://doi.org/10.1007/978-3-319-27651-9_10)
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), 1–31. <https://doi.org/10.3390/rs12193136>
- Smith, G. M., & Milton, E. J. (1999). The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of Remote Sensing*, 20(13), 2653–2662. <https://doi.org/10.1080/014311699211994>
- Srinivasan, A. (2006). *Principles of Precision Agriculture*. 734.
- Steiner, F., Marzoff, I., & D'Oleire-Oltmanns, S. (2015). Hydrologic validation of a structure-from-motion DEM derived from low-altitude UAV imagery. *Geophysical Research Abstracts*, 17, 10127.
- Thenkabail, P. S., Smith, R. B., & De Pauw, E. (1995). Wiegand and Richardson, † International Center for Agricultural Research in the Dry Areas 1990), natural vegetation (Friedl et al., 1994), and in (ICARDA). *Environ*, 71(99), 158–182. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.472.6217&rep=rep1&type=pdf>

United Nations, & Department of Economic and Social Affairs. (2017). *World population prospects: the 2017 revision, key findings and advance tables*.

van der Merwe, D., Burchfield, D. R., Witt, T. D., Price, K. P., & Sharda, A. (2020). Drones in agriculture. In *Advances in Agronomy* (1st ed., Vol. 162). Elsevier Inc. <https://doi.org/10.1016/bs.agron.2020.03.001>

Villegas Vega, H. (2008). *Introducción a la Percepción Remota y sus Aplicaciones Geológicas*. 64.

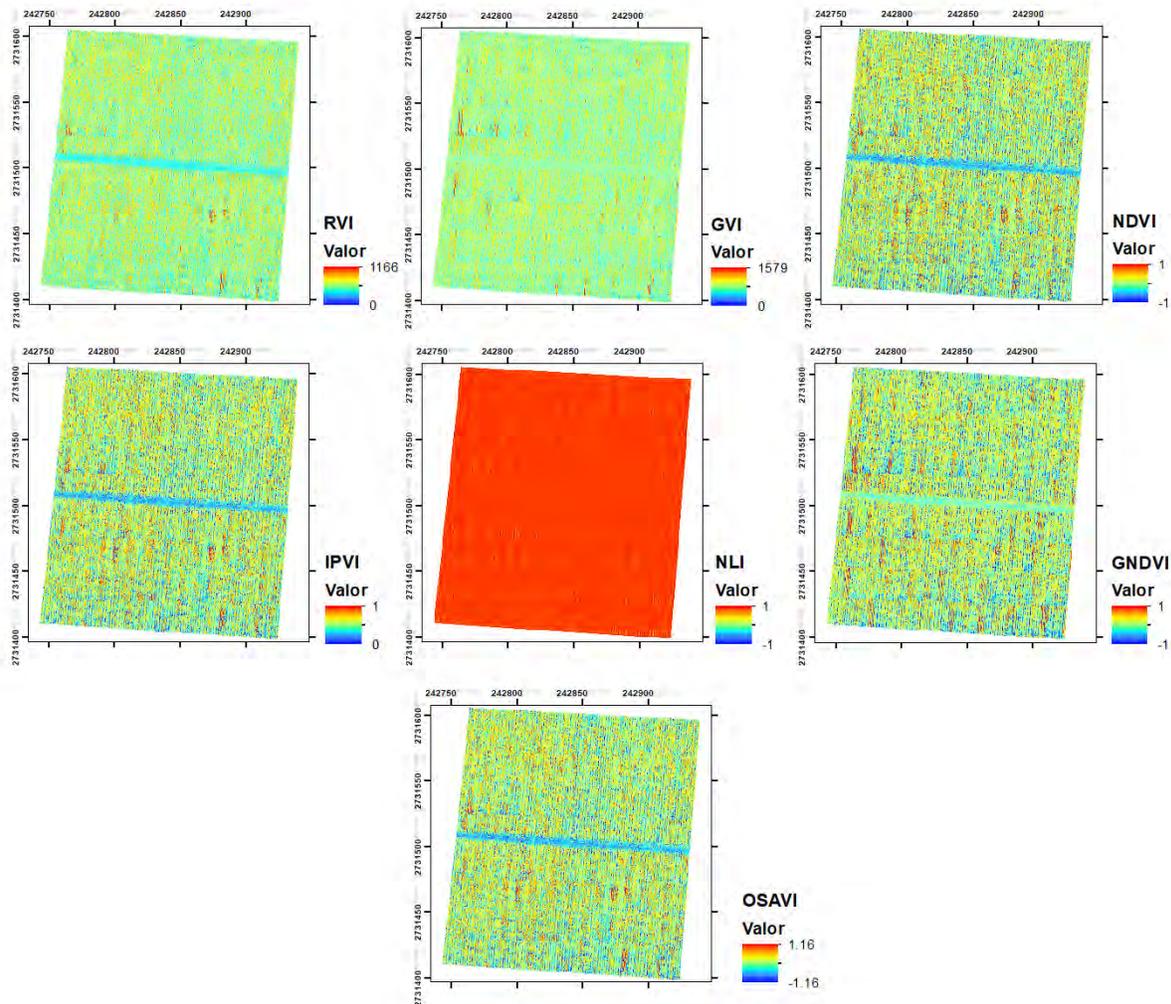
Wolf, P. R., Dewitt, B. A., & Wilkinson, B. E. (2014). Elements of Photogrammetry with Application in GIS. In *Journal of Chemical Information and Modeling*.

Zhang, Q. (2016). *Precision agriculture technology for crop farming*.

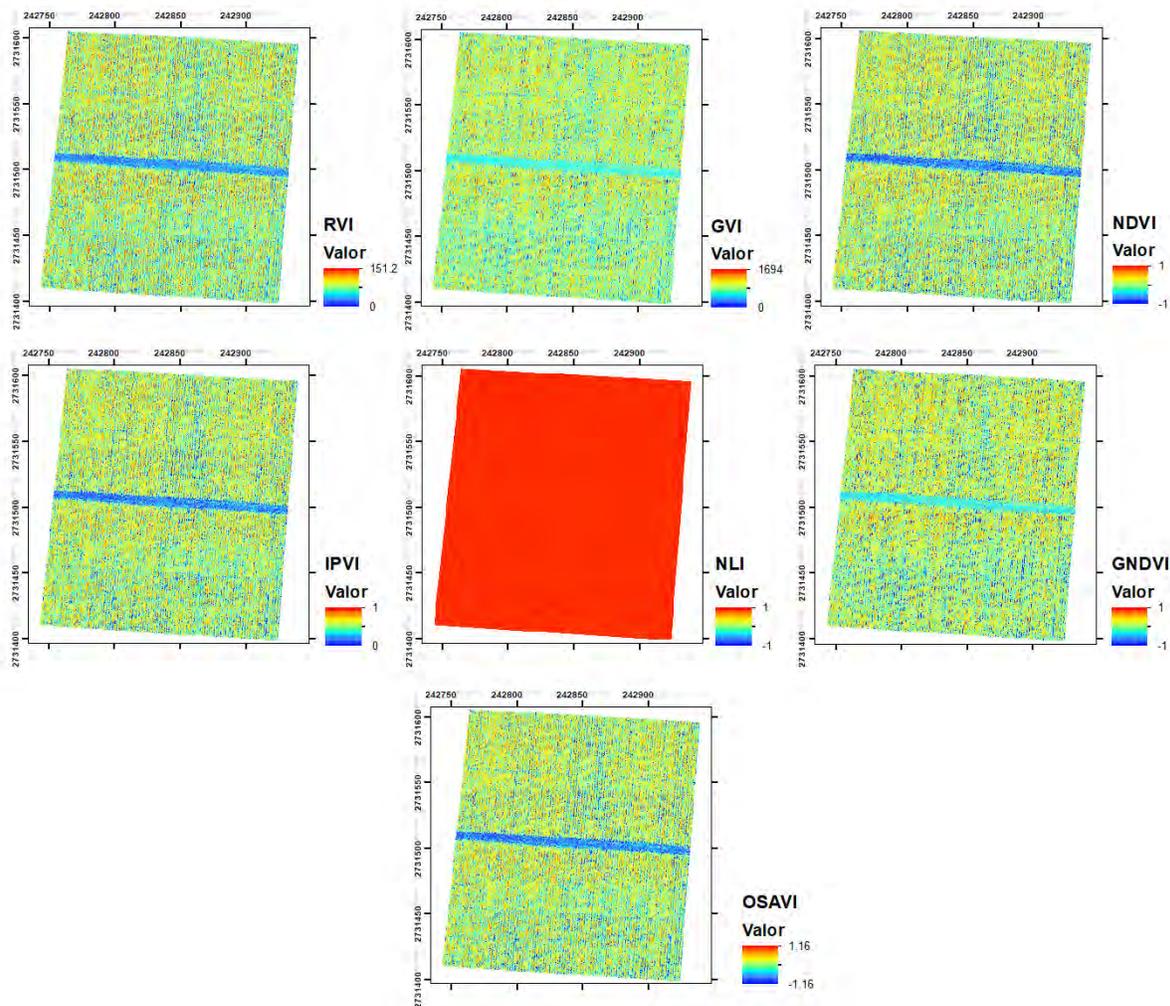
## 6. Anexos

Anexo 7.1. IV aplicados en los siete vuelos realizados.

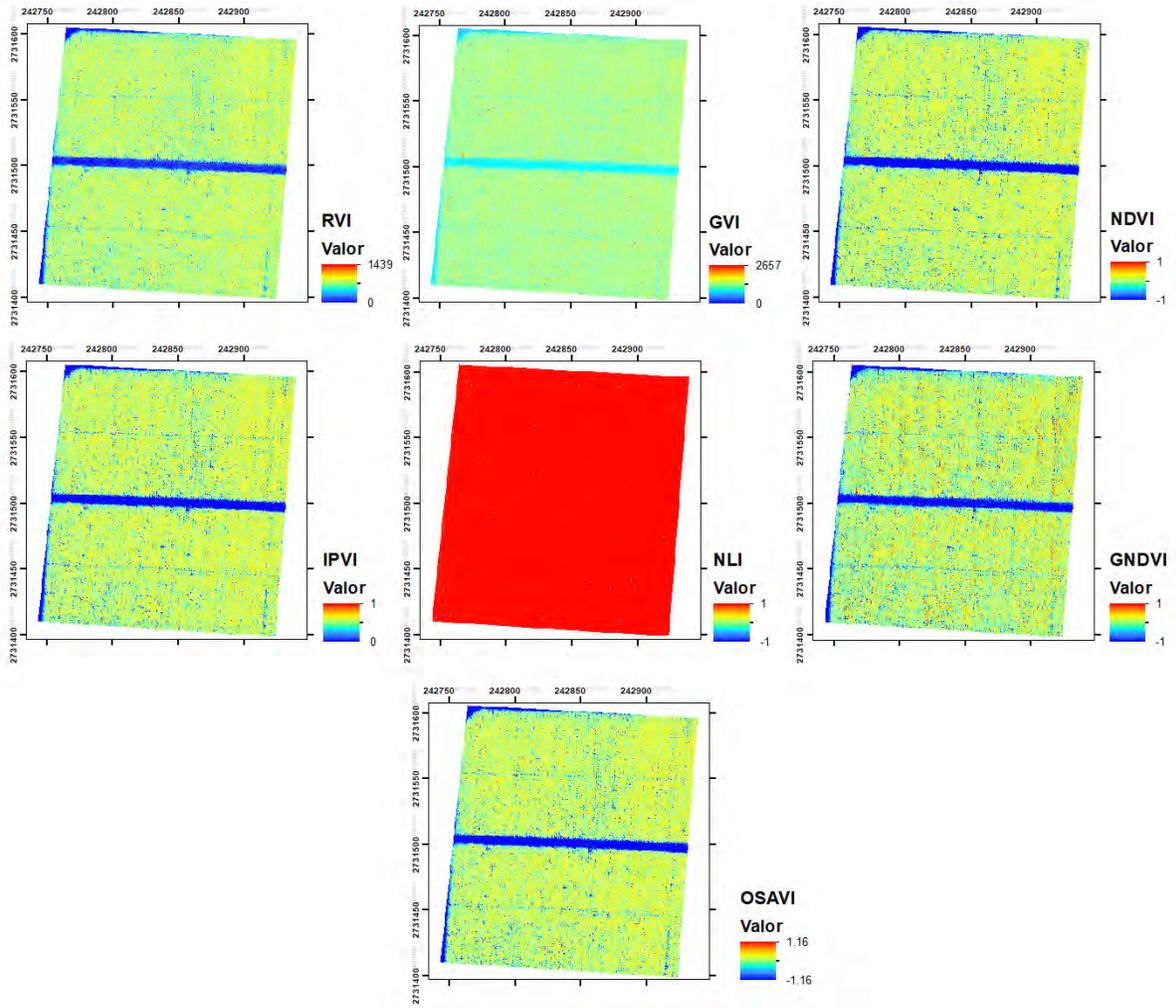
Fecha: 15/10/21



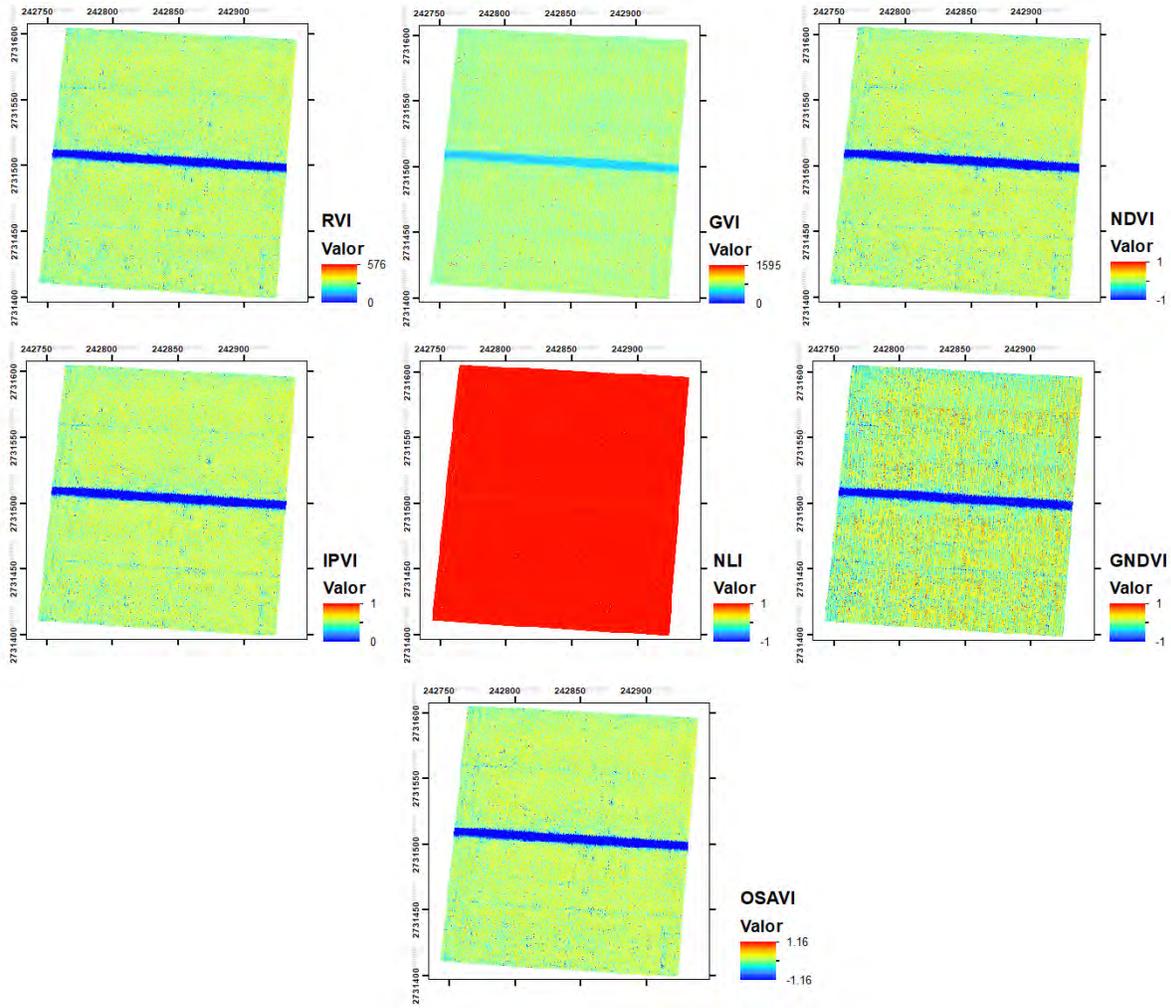
Fecha: 24/10/21



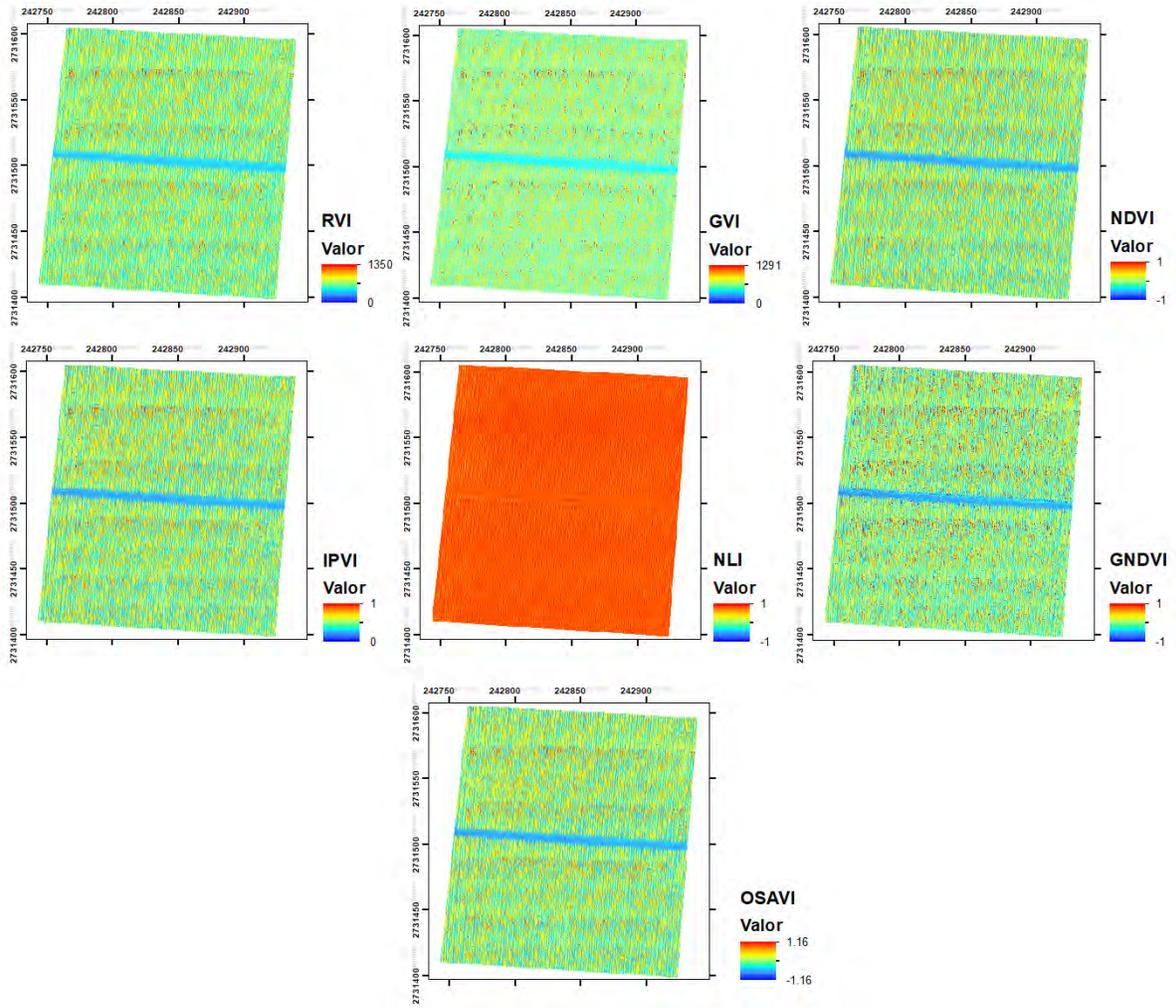
Fecha: 10/11/21



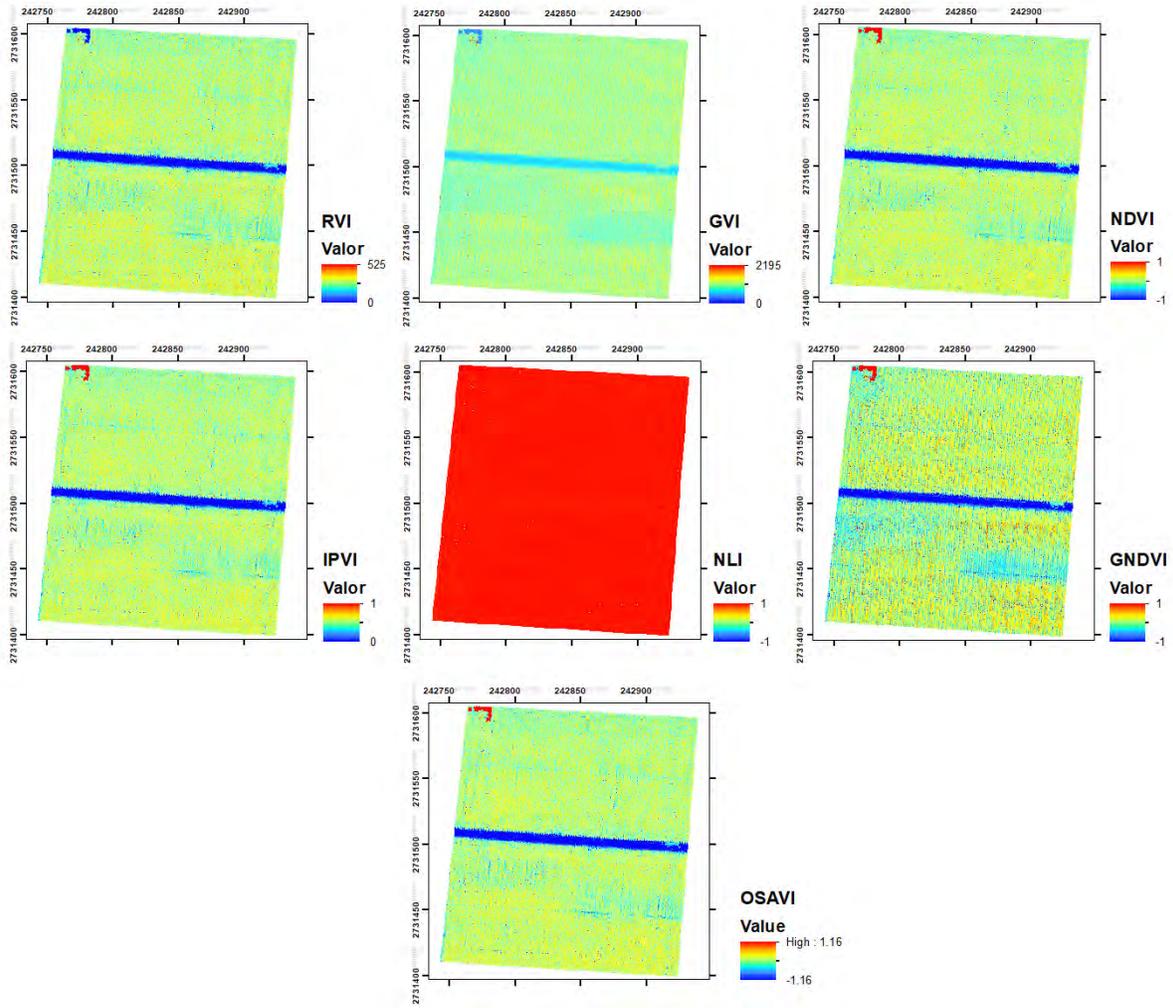
Fecha: 21/11/21



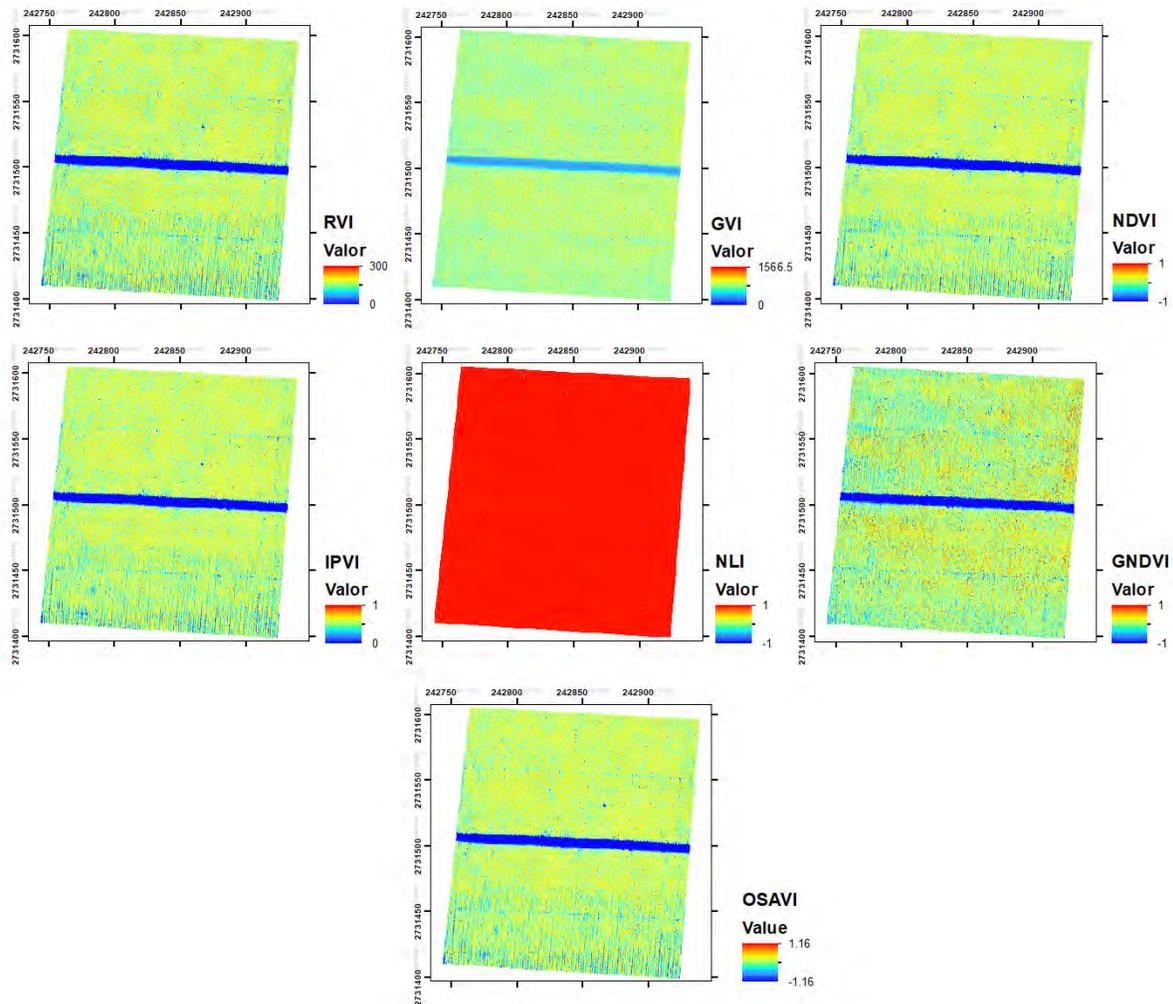
Fecha: 03/12/21



Fecha: 18/12/21



Fecha: 23/01/22



**Anexo 7.1.** Ejemplo del vuelo V7 Código en R.

```
library(sp)
```

```
library(raster)
```

```
library(rgdal)
```

```
T1<-shapefile("E:\AREA2_T1.shp")
```

```
T2<-shapefile("E:\AREA2_T2.shp")
```

```
PLANT_T1<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_MASC230122_PLANT.rst")
```

```
PLANT_T2<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_MASC230122_PLANT.rst")
```

```
PLANT_T1[PLANT_T1==0]<-NA
```

```
PLANT_T2[PLANT_T2==0]<-NA
```

```
#23\01\22
```

```
#tabla1
```

```
rvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_RVI_230122")
```

```
rvit1_230122_m<-(rvit1_230122*PLANT_T1)
```

```
prom<- (rvit1_230122.prom <- data.frame(rvit1_230122.mean=cellStats(rvit1_230122_m, "mean")))
```

```
desv<- (rvit1_230122.desv <- data.frame(rvit1_230122.sd=cellStats(rvit1_230122_m, "sd")))
```

```
gvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_GVI_230122")
```

```
gvit1_230122_m<-(gvit1_230122*PLANT_T1)
```

```
prom<- (gvit1_230122.prom <- data.frame(gvit1_230122.mean=cellStats(gvit1_230122_m, "mean")))
```

```
desv<- (gvit1_230122.desv <- data.frame(gvit1_230122.sd=cellStats(gvit1_230122_m, "sd")))
```

```
ndvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_NDVI_230122")
```

```
ndvit1_230122_m<-(ndvit1_230122*PLANT_T1)
```

```
prom<- (ndvit1_230122.prom <- data.frame(ndvit1_230122.mean=cellStats(ndvit1_230122_m, "mean")))
```

```
desv<- (ndvit1_230122.desv <- data.frame(ndvit1_230122.sd=cellStats(ndvit1_230122_m, "sd")))
```

```
ipvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_IPVI_230122")
```

```

ipvit1_230122_m<-(ipvit1_230122*PLANT_T1)

prom<- (ipvit1_230122.prom <- data.frame(ipvit1_230122.mean=cellStats(ipvit1_230122_m, "mean")))

desv<- (ipvit1_230122.desv <- data.frame(ipvit1_230122.sd=cellStats(ipvit1_230122_m, "sd")))

nlit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_NLI_230122")

nlit1_230122_m<-(nlit1_230122*PLANT_T1)

prom<- (nlit1_230122.prom <- data.frame(nlit1_230122.mean=cellStats(nlit1_230122_m, "mean")))

desv<- (nlit1_230122.desv <- data.frame(nlit1_230122.sd=cellStats(nlit1_230122_m, "sd")))

gndvit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_GNDVI_230122")

gndvit1_230122_m<-(gndvit1_230122*PLANT_T1)

prom<- (gndvit1_230122.prom <- data.frame(gndvit1_230122.mean=cellStats(gndvit1_230122_m, "mean")))

desv<- (gndvit1_230122.desv <- data.frame(gndvit1_230122.sd=cellStats(gndvit1_230122_m, "sd")))

osavit1_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T1_OSAVI_230122")

osavit1_230122_m<-(osavit1_230122*PLANT_T1)

prom<- (osavit1_230122.prom <- data.frame(osavit1_230122.mean=cellStats(osavit1_230122_m, "mean")))

desv<- (osavit1_230122.desv <- data.frame(osavit1_230122.sd=cellStats(osavit1_230122_m, "sd")))

#tabla2

rvit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_RVI_230122")

rvit2_230122_m<-(rvit2_230122*PLANT_T2)

```

```
prom<- (rvit2_230122.prom <- data.frame(rvit2_230122.mean=cellStats(rvit2_230122_m, "mean")))
desv<- (rvit2_230122.desv <- data.frame(rvit2_230122.sd=cellStats(rvit2_230122_m, "sd")))
```

```
gvit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_GVI_230122")
gvit2_230122_m<-(gvit2_230122*PLANT_T2)
prom<- (gvit2_230122.prom <- data.frame(gvit2_230122.mean=cellStats(gvit2_230122_m, "mean")))
desv<- (gvit2_230122.desv <- data.frame(gvit2_230122.sd=cellStats(gvit2_230122_m, "sd")))
```

```
ndvit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_NDVI_230122")
ndvit2_230122_m<-(ndvit2_230122*PLANT_T2)
prom<- (ndvit2_230122.prom <- data.frame(ndvit2_230122.mean=cellStats(ndvit2_230122_m, "mean")))
desv<- (ndvit2_230122.desv <- data.frame(ndvit2_230122.sd=cellStats(ndvit2_230122_m, "sd")))
```

```
ipvit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_IPVI_230122")
ipvit2_230122_m<-(ipvit2_230122*PLANT_T2)
prom<- (ipvit2_230122.prom <- data.frame(ipvit2_230122.mean=cellStats(ipvit2_230122_m, "mean")))
desv<- (ipvit2_230122.desv <- data.frame(ipvit2_230122.sd=cellStats(ipvit2_230122_m, "sd")))
```

```
nlit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-22\\T2_NLI_230122")
nlit2_230122_m<-(nlit2_230122*PLANT_T2)
prom<- (nlit2_230122.prom <- data.frame(nlit2_230122.mean=cellStats(nlit2_230122_m, "mean")))
desv<- (nlit2_230122.desv <- data.frame(nlit2_230122.sd=cellStats(nlit2_230122_m, "sd")))
```

```

gndvit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-
22\\T2_GNDVI_230122")

gndvit2_230122_m<-(gndvit2_230122*PLANT_T2)

prom<- (gndvit2_230122.prom <- data.frame(gndvit2_230122.mean=cellStats(gndvit2_230122_m,
"mean")))

desv<- (gndvit2_230122.desv <- data.frame(gndvit2_230122.sd=cellStats(gndvit2_230122_m, "sd")))

osavit2_230122<-raster("E:\\INDICES_CORRECCION\\04_MASC_PLANTA\\23-01-
22\\T2_OSAVI_230122")

osavit2_230122_m<-(osavit2_230122*PLANT_T2)

prom<- (osavit2_230122.prom <- data.frame(osavit2_230122.mean=cellStats(osavit2_230122_m,
"mean")))

desv<- (osavit2_230122.desv <- data.frame(osavit2_230122.sd=cellStats(osavit2_230122_m, "sd")))

```

**Anexo 7.3.** Tablas ANOVA de los índices RVI, GVI, NDVI, IPVI, NLI, GNDVI y OSAVI despectivamente.  
**RVI**

Fuente	Suma de Cuadrados	Grados de libertad	Cuadrado Medio	Razón-F	Valor-P
Efectos principales					
A: Fecha	0.303384	5	0.0606769	2275.01	0
B: Tabla	7.86E-08	1	7.86E-08	0	0.9588
Residuos	0.00013336	5	2.6671E-05		
Total (corregido)	0.303518	11			

**GVI**

Fuente	Suma de Cuadrados	Grados de libertad	Cuadrado Medio	Razón-F	Valor-P
Efectos principales					
A: Fecha	2.74991	5	0.549983	1133.05	0
B: Tabla	7.0509E-05	1	7.0509E-05	0.15	0.7188
Residuos	0.00242699	5	0.0004854		
Total (corregido)	2.75241	11			

**NDVI**

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de libertad</b>	<b>Cuadrado Medio</b>	<b>Razón-F</b>	<b>Valor-P</b>
Efectos principales					
A: Fecha	0.0237227	5	0.00474454	2746.19	0
B: Tabla	1.12E-08	1	1.12E-08	0.01	0.9389
Residuos	8.6384E-06	5	1.7277E-06		
Total (corregido)	0.0237314	11			

#### IPVI

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de libertad</b>	<b>Cuadrado Medio</b>	<b>Razón-F</b>	<b>Valor-P</b>
Efectos principales					
A: Fecha	0.00592846	5	0.00118569	2860.2	0
B: Tabla	6.19E-09	1	6.19E-09	0.01	0.9075
Residuos	2.0728E-06	5	4.15E-07		
Total (corregido)	0.00593054	11			

#### NLI

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de libertad</b>	<b>Cuadrado Medio</b>	<b>Razón-F</b>	<b>Valor-P</b>
Efectos principales					
A: Fecha	2.08E-08	5	4.16E-09	1.87	0.2541
B: Tabla	3.34E-09	1	3.34E-09	1.51	0.2744
Residuos	1.11E-08	5	2.22E-09		
Total (corregido)	3.52E-08	11			

#### GNDVI

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de libertad</b>	<b>Cuadrado Medio</b>	<b>Razón-F</b>	<b>Valor-P</b>
Efectos principales					
A: Fecha	0.240313	5	0.0480626	2037.24	0
B: Tabla	1.3587E-05	1	1.3587E-05	0.58	0.4821
Residuos	0.00011796	5	2.3592E-05		
Total (corregido)	0.240445	11			

#### OSAVI

<b>Fuente</b>	<b>Suma de Cuadrados</b>	<b>Grados de libertad</b>	<b>Cuadrado Medio</b>	<b>Razón-F</b>	<b>Valor-P</b>
Efectos principales					
A: Fecha	0.034212	5	0.0068424	61.82	0.0002
B: Tabla	8.9931E-05	1	8.9931E-05	0.81	0.4087
Residuos	0.00055337	5	0.00011067		

Total (corregido)	0.0348553	11
-------------------	-----------	----

---