

UNIVERSIDAD DE COSTA RICA
FACULTAD DE CIENCIAS AGROALIMENTARIAS
ESCUELA DE AGRONOMÍA

TESIS PARA OPTAR AL TÍTULO PROFESIONAL DE INGENIERO
AGRÓNOMO CON EL GRADO DE LICENCIADO EN AGRONOMÍA

**Valores de referencia de seis índices de vegetación para las variedades de arroz
(*Oryza sativa*) Lazarroz y Senumisa 20, en Costa Rica durante la época lluviosa**

Estudiante: Anthony John Villegas Torres

Carné: B47675

2022

San José, Costa Rica

Valores de referencia de seis índices de vegetación para las variedades de arroz (*Oryza sativa*) Lazarroz y Senumisa 20, en Costa Rica durante la época lluviosa

Anthony John Villegas Torres

TESIS PARA OPTAR AL TÍTULO PROFESIONAL DE INGENIERO AGRÓNOMO
CON EL GRADO DE LICENCIADO EN AGRONOMÍA



Siso Rachith Acuña Chinchilla. M. Sc.

Director tesis



Guillermo Vargas Hernández. M. Sc.

Miembro tribunal



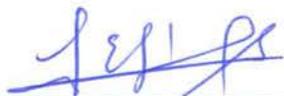
Marco Vinicio Gutiérrez Soto. Ph. D.

Miembro tribunal



Franklin Herrera Murillo. Ph. D.

Miembro tribunal



Luis Gómez Alpizar. Ph. D.

Director de la Escuela de Agronomía



Anthony John Villegas Torres

Sustentante

2022.

Agradecimientos y dedicatorias

Le agradezco a mi familia y a la Universidad de Costa Rica por darme la oportunidad de realizar esta tesis. A mis amigos y compañeros por ofrecerse a ayudarme con las distintas labores necesarias para llevar a cabo la investigación. Al profesor M. Sc. Sisgo Rachith Acuña Chinchilla que me guió y me apoyó en el proceso, y a los profesores M. Sc. Guillermo Vargas Hernández, y Dr. Marco Vinicio Gutiérrez Soto, como lectores de tesis, por su apoyo y orientación durante la realización del ensayo de campo, el análisis de los datos y la revisión de este documento. También a la empresa Hacienda el Pelón de la Bajura por la ayuda e insumos brindados, a la Estación Experimental Fabio Baudrit Moreno y Centro de Investigaciones de Granos y Semillas y a sus funcionarios por la ayuda y equipo brindado.

Índice

Resumen.....	8
1.Introducción	10
2.1 Objetivo general.....	13
2.2. Objetivos específicos	13
3. Marco teórico.....	14
3.1. Usos generales de la Teledetección	14
3.2 Conceptos básicos.....	15
3.2.1. Espectro electromagnético	15
3.2.2. Tipos de sensores.....	16
3.2.3. Características de los datos	16
3.2.4. Plataformas.....	17
3.3. Índices de vegetación	18
3.4 Teledetección y la agricultura.....	19
3.5 Aplicaciones de la teledetección en arroz y otros cultivos.....	22
3.6. Determinación del Índice de Área Foliar	27
4. Metodología	30
4.1. Localización.....	30
4.2. Material Experimental.....	30
4.3. Procedimiento general.....	30
4.5 Diseño experimental	34
4.6 Análisis estadísticos de datos	34
5. Resultados.....	35
5.1. Análisis de correlación de Pearson entre bandas espectrales e índices de vegetación con respecto al IAF.	35
5.2. Análisis descriptivo del comportamiento de las bandas espectrales con respecto a la suma térmica.	35
5.3. Análisis descriptivo del comportamiento de los índices de vegetación con respecto a la suma térmica.	38
5.4. Valores de referencia de las bandas e índices de vegetación y su variación. ...	42

6. Discusión	50
6.1. IAF y reflectancia	50
6.2. Índices de vegetación	50
6.3. Índice de Área foliar.....	52
6.4. Rendimiento.....	54
7. Conclusiones y Recomendaciones	56
8. Anexos	57
Anexo 1. Valores óptimos de contenido foliar de nutrientes en el cultivo de arroz (Molina, 2012)......	57
Anexo 2. Resultados de los análisis químicos foliares para las variedades Senumisa 20 y Lazarroz, de las muestras tomadas en la etapa de hoja bandera.	57
Anexo 3. Resultados del análisis químico completo de suelos para las variedades Senumisa 20 y Lazarroz.	57
Anexo 4. Valores reales de IAF contra el promedio de los valores estimados con el ceptómetro durante 8 semanas para la variedad Senumisa 20, $R^2= 0,97$	58
Anexo 5. Valores reales de IAF contra el promedio de los valores estimados con el ceptómetro durante 10 semanas para la variedad Lazarroz, $R^2= 0,98$	58
10. Bibliografía	59

Índice de Figuras

Figura 1. Parcelas de arroz en secano de las variedades Senumisa 20 (izquierda) a 100 días después de la emergencia y Lazarroz (derecha) a 70 días después de la emergencia, en la Estación Experimental Agrícola Fabio Baudrit Moreno durante la época lluviosa.	30
Figura 2. Diagramas de cajas con el promedio, cuartil inferior y superior de la reflectancia de las bandas verde (550 ± 15 nm) y roja (670 ± 15 nm), con respecto a la suma térmica para la variedad Senumisa 20 ^e	36
Figura 4. Diagramas de cajas con la mediana, cuartil inferior y superior de los Índices de vegetación WDRVI y RVI con respecto a la suma térmica de la variedad Senumisa 20.....	39
Figura 5. Diagramas de cajas con la mediana, cuartil inferior y superior de los Índices de vegetación NDRE y TVI, con respecto a la suma térmica de la variedad Senumisa 20.....	40
Figura 6. Diagramas de cajas con la mediana, cuartil inferior y superior del Índices de vegetación WDRVI y RVI con respecto a la suma térmica de la variedad Lazarroz .	41
Figura 7. Diagramas de cajas con la mediana, cuartil inferior y superior del Índices de vegetación NDRE y TVI con respecto a la suma térmica de la variedad Lazarroz	42
Figura 8. IAF promedio según la suma térmica para cada variedad desde los 15 días después de emergencia hasta la etapa de hoja bandera.	46
Figura 9. Modelo de regresión para predecir el IAF con respecto al NDRE para la variedad Senumisa 20, n= 90, R2= 0,86.....	47
Figura 10. Modelo de regresión para predecir el IAF con respecto al NDRE para la variedad Lazarroz, n= 99, R2 = 0,77.....	48

Índice de cuadros

Cuadro 1. Coeficientes de correlación de Pearson (r) entre las bandas espectrales y los índices de vegetación contra el IAF según la variedad de arroz.....	35
Cuadro 2. Valores promedio, desviación estándar y coeficiente de variación de las bandas e Índices de vegetación seleccionados con respecto a los grados día acumulados para la variedad Senumisa 20.	44
Cuadro 3. Valores promedio, desviación estándar y coeficiente de variación de las bandas e Índices de vegetación seleccionados con respecto a los grados día acumulados para la variedad Lazarroz.....	45
Cuadro 4. Coeficientes de correlación de Pearson (r) de las bandas espectrales y los índices de vegetación contra el rendimiento en Kg ha ⁻¹ según la variedad de arroz. .	49

Resumen

El uso de la teledetección en la agricultura como fuente de información para la toma de decisiones ha aumentado durante las últimas décadas. Por esto, una investigación descriptiva fue establecida en la Estación Experimental Agrícola Fabio Baudrit Moreno con el objetivo de generar valores de referencia de seis índices de vegetación (WDRVI, RDVI, RVI, RGBVI, NDRE y TVI), para el monitoreo del crecimiento y rendimiento del cultivo del arroz. Se establecieron dos parcelas experimentales en secano favorecido (al inicio de la época lluviosa) con alta densidad de siembra 150 kg ha^{-1} , con las variedades Lazarroz y Senumisa 20, las cuales son las más utilizadas en Costa Rica. En las parcelas se midieron las firmas espectrales y se estimó el índice de área foliar (IAF) en puntos fijos semanalmente. Además, se realizó un vuelo y se tomaron imágenes multiespectrales y RGB con un dron en la etapa de máximo desarrollo vegetativo, se midió el rendimiento y se realizaron análisis de correlación entre los índices de vegetación y la reflectancia de las bandas azul, verde, rojo, borde rojo e infrarrojo cercano contra el IAF, y se elaboraron tablas de referencia con los valores con buenas correlaciones ($r \geq 0,6$) con respecto a los grados día acumulados. También se elaboraron modelos de regresión para estimar el IAF con las relaciones con mejor coeficiente de determinación ($R^2 > 0,7$). Además, se realizaron análisis de correlación entre los valores de reflectancia de las bandas y los índices de vegetación con respecto al rendimiento. El rendimiento de las parcelas fue de 8 y $10,5 \text{ t ha}^{-1}$ y el IAF máximo fue de 10,5 y 17,8 para la variedad Senumisa 20 y Lazarroz respectivamente. Se obtuvieron buenos valores de correlación con respecto al IAF para las bandas rojas, y azul, y para los índices WDRVI, RVI y TVI. Sin embargo, los valores más altos fueron para el índice NDRE (0,93 y 0,88 para Senumisa 20 y Lazarroz respectivamente). El NDRE también fue el que mejor correlación tuvo con el rendimiento (0,71 y 0,81 para Senumisa 20 y Lazarroz respectivamente). Los modelos de regresión se elaboraron únicamente para el NDRE los cuales tuvieron R^2 de 0,77 y 0,86 para las variedades Lazarroz y Senumisa 20 respectivamente. En conclusión, los valores de referencia reportados son válidos para ser utilizados como un insumo para la toma de decisiones en el manejo del cultivo relacionado con la modulación del crecimiento del arroz con la finalidad de alcanzar buenos rendimientos.

Ficha Bibliográfica

Villegas Torres, Anthony John. “Valores de referencia de seis índices de vegetación para las variedades de arroz (*Oryza sativa*) Lazarroz y Senumisa 20, en Costa Rica durante la época lluviosa” Tesis para optar al título profesional de Ingeniero Agrónomo con el grado de Licenciado en Agronomía, Facultad de Agronomía, Universidad de Costa Rica, San José, Costa Rica.

Director: Sisgo Rachith Acuña Chinchilla.

Palabras clave: Índices de Vegetación, Cultivo de Arroz, Teledetección, Índice de Área Foliar

1.Introducción

Según Olson et al., (2019) la teledetección y el uso de índices de vegetación es uno de los fundamentos de la agricultura de precisión. Esta herramienta tiene la función de monitorear de manera remota grandes o pequeñas extensiones de cultivo, lo cual depende del instrumento y el vehículo de colección de imágenes, ya sean imágenes satelitales o mediante vehículos aéreos no tripulados. Esta disciplina utiliza imágenes multispectrales que capturan la radiación reflejada por las diferentes superficies en las ondas de luz rojo, verde, azul e infrarrojo, entre otras, con el propósito de poder calcular índices de vegetación (Chen, 2017). Estos índices son el resultado de operaciones aritméticas entre los valores de reflectancia de distintas ondas de luz (Dentro del rango visible e infrarrojo) que a su vez se correlacionan con distintos parámetros del cultivo (Weiss et al., 2020). Con esto se generan mapas del estado de salud del cultivo que dimensionan de forma espacial el área afectada, para focalizar las acciones correctivas a las regiones y en la medida que lo necesitan, así se disminuyen costos, el impacto medioambiental y se aumentan los rendimientos.

Existen diversos índices de vegetación creados de la investigación de distintas instituciones para correlacionarlos con las variables morfológicas y fisiológicas del cultivo, sin embargo, el más conocido es el índice de vegetación de diferencia normalizado (NDVI por sus siglas en inglés), debido a que este compara la proporción de luz roja con la infrarroja, estas frecuencias de onda de luz están correlacionadas con la tasa fotosintética y por ende, indirectamente correlacionadas con la salud y desarrollo de las plantas (Weiss et al., 2020). Algunos índices de vegetación han mostrado ser útiles no solo para detectar de forma precisa las áreas afectadas o más productivas de la plantación, al comparar la variabilidad de este índice dentro de la misma, sino para generar modelos matemáticos para predecir y estimar el rendimiento, el índice de área foliar y la fenología, entre otras variables en diferentes especies de plantas (Weiss et al., 2020). Estos modelos han sido utilizados en distintos cultivos como por ejemplo en trigo (Muriado et al., 2007), arroz (Zhang et al., 2019) y el maíz (Panek & Gozdowski, 2020). El estudio del comportamiento de los índices de vegetación y su correlación con distintas variables, como el rendimiento, no son

extrapolables entre variedades de una misma especie debido a que el potencial de producción y las características fisiológicas y fenológicas varían de un material a otro incluso bajo las mismas condiciones ambientales debido al factor genético (Weiss et al; 2020).

El uso de índices de vegetación puede ser de mucha utilidad en cultivos de alta importancia en la dieta los costarricenses, como el frijol y el arroz, como una herramienta de manejo que ayude a aumentar la productividad de estos al tener información más precisa del vigor del cultivo. En Costa Rica en el periodo del 2015-2016 se sembraron un total de 49 573 ha de arroz, mientras que en el periodo 2019-2020 el área sembrada fue de 33 048 ha. La mayor proporción del área sembrada se encuentra en la región Chorotega, con un total de 9 809 ha. La productividad aumentó de 3,8 t ha⁻¹ en el periodo 2015-2016 a 4,5 ha⁻¹ en 2019-2020, lo que significó un total de 149 339 t (CONARROZ, 2020). Sin embargo, aunque se haya dado un aumento en el rendimiento, estos siguen siendo bajos si se comparan con países como Uruguay, del cual se importaron 20 000 toneladas métricas de arroz en granza para el periodo 2019-2020, donde el rendimiento promedio para 2017-2018 fue de 8 ha⁻¹ según el Instituto Nacional de Investigación Agropecuaria de Uruguay (F. Molina et al., 2019).

La competitividad en el cultivo del arroz ha sido un tema recurrente en el contexto nacional debido a la posible liberación del precio y la reducción de aranceles al arroz importado, por lo que es necesario realizar esfuerzos en pro del aumento de la precisión en el diagnóstico y la aplicación de insumos para incrementar el rendimiento y la rentabilidad de la actividad. Una de las herramientas potenciales para conseguirlo es el uso de índices de vegetación obtenidos a partir de imágenes multiespectrales mediante sensores remotos de drones o satélites, los cuales al compararse con índices óptimos permitirían ubicar áreas con problemas de crecimiento de una manera rápida y a bajo costo, y ser utilizados como herramienta en la toma de decisiones sobre las correcciones que deben hacerse en el manejo del cultivo en el momento apropiado.

La presente investigación busca aportar conocimiento sobre el comportamiento de varios índices de vegetación correlacionándolos con un estado por encima del promedio del cultivo el cuál será cuantificado con valores de índice de área foliar y

rendimiento. Esto aumentaría la precisión y la cantidad de la información del crecimiento y la productividad del cultivo de arroz, así se aprovecharía de mejor manera el uso de imágenes multispectrales tomadas desde drones, y potencialmente aumentaría la rentabilidad del mismo, al disminuir los costos debido a la aplicación de insumos de forma precisa y aumentar el rendimiento al tomar acciones en el momento adecuado.

2. Objetivos

A continuación, se presentan los objetivos generales y específicos de la investigación.

2.1 Objetivo general

Determinar valores de referencia de seis índices de vegetación para las variedades de arroz Senumisa 20 y Lazarroz durante la época lluviosa, mediante correlaciones con el índice de área foliar para el monitoreo del crecimiento de estas variedades.

2.2. Objetivos específicos

1) Obtener los índices de vegetación WDRVI, RDVI, RVI, RGBVI, NDRE y TVI, para las variedades de arroz Senumisa 20 y Lazarroz, durante la época lluviosa.

2) Determinar la correlación de los índices de vegetación y las bandas espectrales con respecto al índice de área foliar para las variedades de arroz Senumisa 20 y Lazarroz durante la época lluviosa.

3) Generar rangos de valores de referencia de los índices de vegetación y las bandas espectrales para las variedades de arroz Senumisa 20 y Lazarroz durante la época lluviosa, en función de los grados día acumulados como guía de la productividad potencial del cultivo.

3. Marco teórico

La teledetección para agricultura es una disciplina en la que se utilizan técnicas de Sistemas de información geográfica, procesamiento de imágenes, física y agronomía.

3.1. Usos generales de la Teledetección

El proceso de teledetección se basa en la adquisición de imágenes de manera remota, para posteriormente ser analizada de forma que se pueda obtener información espacial útil, la cual será el insumo para investigación, planificación o manejo del área de interés (Nakhapakorn & Gonzalez, 2000). La calidad de la información dependerá del medio desde el cual se toma la fotografía, el sensor y el análisis de las imágenes.

La teledetección puede utilizarse en varias áreas de la ciencia, para estudiar la biodiversidad, a través de mapas de cobertura vegetal y de sus patrones, para lo cual se monitorean los cambios en la cobertura vegetal y se realizan modelos de la distribución de las distintas especies vegetales (DeFries, 2013). En el área de la Geología se usan los sensores hiperespectrales colocados en aeronaves o bien mediante sensores satelitales (como el sensor Hyperion) para exploración de minerales (encontrar minerales de interés utilizando la información espectral), al clasificar y caracterizar la distribución de los distintos materiales presentes en una zona determinada (Guha, 2020). En monitoreo medioambiental es posible precisar la zona y el material con el que está contaminado un territorio, o en algunos casos cuantificar la cantidad de minerales que absorben o pueden albergar a algunos metales pesados (Huete, 2004). La degradación del bioma y el avance de la desertificación también ha sido monitoreada utilizando imágenes espectrales satelitales en el noreste de Brasil (Oliveira et al., 2020)

En Topografía es recurrente el uso de la teledetección para la modelación del terreno, debido a la alta precisión que requieren estas tareas para uso civil, por lo general se utilizan aeronaves o drones con sistemas de navegación global de alta precisión junto con sensores LiDAR (del inglés Laser Imaging Detection and Ranging (Detección y Rango de Imágenes Láser)). En Meteorología para generar modelos

climatológicos se utilizan datos atmosféricos como la temperatura, la precipitación y la nubosidad obtenidos mediante teledetección (Horning, 2008). Así, en muchas otras áreas de la ciencia, la teledetección es aprovechada para el beneficio de la sociedad, ya que aumentan la eficiencia de procesos de medición altamente laboriosos. La teledetección también es utilizada en agricultura de precisión para determinar algunas variables del cultivo de manera indirecta, plagas y enfermedades, predecir el rendimiento, ajustar el riego y detectar malezas, entre otros (Weiss et al., 2020).

3.2 Conceptos básicos

Para comprender como se llevan a cabo las aplicaciones mencionadas, a continuación, se detallan algunos conceptos básicos necesarios para comprender el proceso de teledetección.

3.2.1. Espectro electromagnético

La mayor parte de la radiación que llega a la tierra proviene del sol. El espectro electromagnético es la variedad de intensidades de ondas que se pueden encontrar, cuanto más corta la longitud de la onda más energética es esta. En la agricultura se utiliza principalmente la franja visible y el infrarrojo, ya que en estas regiones se encuentra la radiación fotosintéticamente activa (PAR) y en el infrarrojo térmico es posible detectar el sobrecalentamiento de las plantas. En teledetección se utiliza la reflectancia, que es la fracción de luz incidente reflejada por una superficie. Al ser una proporción, esta se mide en porcentaje (Horning, 2008).

Al utilizar la reflectividad de una superficie es posible crear la firma espectral, que describe la forma en la que distintas superficies reflejan la radiación electromagnética que las incide, esta depende de varios factores como la presencia o ausencia de pigmentos, la posición y la forma de distintos elementos con una reflectancia característica sobre la superficie (Huete, 2004). Por ejemplo, las plantas poseen distintos pigmentos como la clorofila a y b que absorben la luz azul (400 a 500 nm) y roja (600 a 700 nm) del espectro visible, además de otros pigmentos como el caroteno y las xantofilas que absorben luz azul (Chen, 2017).

Los pigmentos de las plantas absorben una menor cantidad de verde con respecto al rojo o azul, y son prácticamente transparentes para el infrarrojo cercano y la absorción en las hojas es baja, por lo que la mayoría de la radiación en esta banda (región del espectro electromagnético) es reflejada (Huete, 2004). La sección entre el rojo y el infrarrojo cercano es conocida como borde rojo y es utilizada en la detección de vegetación estresada (Cui & Kerekes, 2018).

3.2.2. Tipos de sensores

Los sensores utilizados para capturar la reflectancia de los objetos son en su mayoría cámaras de muy alta resolución que capturan la radiación de un número determinado de ondas, lo que genera una imagen de varios píxeles, cada píxel con un valor de reflectancia para cada longitud de onda. Las imágenes pueden ser analizadas mediante el uso de software para el análisis de imágenes, como QGIS, Pix4D, y utilizando inteligencia artificial, entre otros (Horning, 2008). Los sensores pueden ser clasificados en pasivos y activos, los primeros necesitan de una fuente externa de radiación como el sol, mientras que los sensores activos no necesitan de una fuente externa de radiación ya que ellos mismos poseen una (Lee & Wong, 2018).

Debido a que los sensores pasivos dependen de la luz solar para operar, las mediciones solo pueden ser realizadas durante el día. Los sensores activos por otro lado pueden funcionar a cualquier hora. Otra desventaja de los sensores pasivos es que, al medir la reflectancia en zonas boscosas o cultivos estratificados, la radiación del sol podría no penetrar en los estratos más bajos. Los sensores pasivos trabajan principalmente en el rango del espectro visible y el infrarrojo (Leslie, 2017).

3.2.3. Características de los datos

Las imágenes capturadas por un sensor espectral tienen varias características como la resolución espacial, espectral, temporal y radiométrica. La resolución espacial se refiere al área más pequeña que puede ser representada por el sensor, cuanto mayor sea la resolución, mayor será la variabilidad de objetos de distintos tamaños que pueden ser capturados por el mismo. La resolución espectral de un sensor es la cantidad de bandas (región del espectro electromagnético) y ancho de las mismas, hay sensores que

poseen bandas muy estrechas por lo que solo detectan la reflectancia de una longitud de onda específica, otros, como los sensores hiperespectrales poseen cientos de bandas estrechas; también están los que poseen sensores pancromáticos que detectan la radiación de una banda ancha (Liang & Wang, 2020). La resolución temporal se refiere a la frecuencia con la que se obtienen los datos, los satélites por ejemplo tienen una resolución de días. La resolución radiométrica es la sensibilidad del sensor y depende del número de bits en el que la radiación capturada es dividida, cuanto mayor más sensible es el valor obtenido (Liang & Wang, 2020a).

3.2.4. Plataformas

Para obtener imágenes de manera remota es necesario que los sensores sean colocados en plataformas móviles. Toth y Józskó (2016), realizaron una revisión sobre el estado del arte en el campo de la teledetección enfocado en los principales avances con respecto a las plataformas en las cuales están colocados los sensores y en los sensores mismos. En cuanto a las plataformas utilizadas, estas son principalmente tres: satélites, planeadores o aviones y vehículos aéreos no tripulados.

Los satélites llevan más de 40 años orbitando la tierra y actualmente hay más de 50 países con satélites registrados para teledetección (Toth & Józskó, 2016). Los principales avances han sido una mejora en cuanto a la resolución espectral y espacial, también se ha migrado de un modelo en el que un solo satélite opera de forma individual con un solo sensor para una misión en específico, a un modelo cooperativista en el que hay varios satélites en una misma órbita o en varias a la vez para aumentar la resolución temporal, abarcando mayor diversidad de lugares y aumentando la cantidad de imágenes (Unninayar & Olsen, 2015). Los sistemas que operan en tándem con distintos sensores por otra parte son conocidos como constelación (Singh et al., 2020).

Las aeronaves por otro lado no han avanzado tanto como los satélites, desde que la resolución espacial de los sensores utilizados en los satélites ha mejorado, por lo que el uso de aeronaves ha disminuido. El avance en la teledetección de aeronaves ha estado ligado más al de los sensores mismos que en las plataformas, por ejemplo, con la utilización de los sensores LiDAR se requiere de una menor velocidad de vuelo

por lo que en lugares de alta densidad de vegetación donde se requiera utilizarlos se prefieren helicópteros como plataformas (Mastelic et al., 2020).

Los vehículos aéreos no tripulados conocidos comúnmente como drones han tenido grandes avances en cuanto a formas, materiales, energía y sensores (Yin et al., 2019). En comparación con las otras dos plataformas, los drones han estado presentes por poco tiempo en el sector, pueden variar en muchas formas (Toth & Józkw, 2016). Los drones pequeños con un peso inferior a los 25 kg son los más utilizados. Estos pueden clasificarse según su forma de propulsión como ala fija y multirotor. Los drones de ala fija pueden estar más tiempo en el aire debido a su mecanismo de planeación, son mayormente utilizados en labores de productividad. Los drones multirotor, aunque están por menos tiempo en el aire poseen un mayor control y estabilidad, por lo que se utilizan principalmente en investigaciones donde no se requiere abarcar grandes extensiones. Los sistemas de navegación de los drones son por lo general de baja precisión, sin embargo, actualmente existen drones con sistemas de navegación más precisos los cuales tienen un costo superior (Mohd Noor et al., 2018).

3.3. Índices de vegetación

Utilizar las imágenes capturadas por sensores multiespectrales permite estimar distintos parámetros de la vegetación como la fenología, el estado nutricional, la sanidad, el vigor, la altura, el potencial productivo, entre otros, estos pueden ser determinados utilizando los índices de vegetación, los cuales consisten en fórmulas aritméticas entre distintas bandas. El índice de diferencia normalizado (NDVI) [1] por ejemplo, es uno de los índices de vegetación más conocidos, utiliza las bandas rojo (700 nm) e infrarrojo (alrededor de los 780-1300 nm) basándose en que la mayor proporción de la luz roja es absorbida por el follaje, por el contrario, la mayor parte del infrarrojo cercano es reflejada (Horning, 2008). A continuación la fórmula del NDVI:

$$NDVI = \frac{(\text{Infrarrojo}-\text{Rojo})}{(\text{Infrarrojo}+\text{Rojo})} \quad (1)$$

Por lo general para utilizar los índices de vegetación para inferir información del cultivo se realiza un proceso de validación, en el que se mide algún parámetro de interés *in situ* ya sea de forma destructiva o utilizando plantas satélites

(georreferenciadas) y correlacionándolas con los valores de distintos índices de vegetación a través del tiempo, para poder realizar y generar modelos matemáticos conocidos como regresiones (Chen, 2017).

Una revisión sobre los principales índices de vegetación y sus aplicaciones realizada por Xue & Su (2017), llegó a enlistar a más de 100 índices e indican que los que combinaban las bandas del espectro visible y el infrarrojo fueron los mejores para detectar vegetación verde. Los índices de vegetación tienen limitaciones y no deben de escogerse de manera arbitraria, es necesario considerar el propósito con el que fueron creados, el ambiente, la plataforma, el instrumento utilizado y la investigación que lo respalda.

3.4 Teledetección y la agricultura

Desde el año 2013 ha aumentado tres veces el número de publicaciones que incluían las palabras teledetección y agricultura como temas de interés (Weiss et al., 2020), Weiss et al. (2020) agruparon las aplicaciones de la teledetección al campo de la agricultura en cinco grandes grupos.

El primer campo es el mejoramiento o fenotipado, en el mejoramiento genético es necesario realizar muchas mediciones tanto del fenotipo de las plantas como su respuesta al estrés abiótico y biótico. En esta área se han realizado estudios utilizando imágenes RGB (rojo, verde y azul) y multiespectrales, sensores LiDAR o sensores de sonar, junto con Machine Learning (aprendizaje automático) para la interpretación de los datos, existen otras tecnologías que potencialmente serán utilizadas en el futuro como el uso de la fluorescencia para correlacionar el contenido de clorofila y nitrógeno, hoy en día limitadas tecnológicamente a sensores de mano (Machwitz et al., 2021). El uso de imágenes RGB es usado principalmente para el conteo de órganos como flores y frutos. Las imágenes multiespectrales son utilizadas sobre todo para medir el nivel de área verde, contenido de agua, clorofila y nutrientes (Machwitz et al., 2021). Los datos de sensores LiDAR, imágenes de RGB estéreo y sonar se usan para conocer la altura del dosel. Las nubes de puntos en tres dimensiones realizadas utilizando drones con una alta precisión de geolocalización potencialmente se utilizarán para realizar modelos de la arquitectura de la planta. En esta área recientemente se han utilizado una

combinación de imágenes de distintos sensores para encontrar alguna característica de interés. Tilly et al. (2015) correlacionaron datos de la altura de la planta obtenidos mediante un sensor LIDAR e índices de vegetación de datos multiespectrales de un espectrorradiómetro, para estimar la biomasa del cultivo de cebada obteniendo resultados prometedores.

El segundo grupo es el monitoreo del uso de la tierra para agricultura, este es de mayor interés para instituciones nacionales e internacionales para conocer la distribución, tamaño y localización de los distintos cultivos en una región y momento de interés. Además, para conocer las principales prácticas de manejo y la modificación que estas ejercen sobre el relieve y el medio ambiente (Weiss et al; 2020). La clasificación de superficies es más sencilla cuando se trata de clasificar grandes ecosistemas como, zonas de vida, urbanización y praderas, pero se complica cuando se tratan de clasificar zonas de acuerdo con el cultivo. Algunas de las limitantes presentes en la actualidad son la baja resolución espacial y espectral que presentan los sensores satelitales ya que sobre todo en países en desarrollo el paisaje del agroecosistema es altamente variable. La extensión de la tierra de los productores pequeños por ejemplo en África es menor a 0,25 ha (Bennett et al., 2020). Los retos que presenta esta labor en el futuro son grandes ya que las prácticas de manejo menos agresivas con el ambiente impuestas por el mercado y las instituciones gubernamentales cambiarán la composición y los patrones de uso de tierra de manera drástica. El uso de inteligencia artificial para el manejo de los datos en esta área promete ser de gran utilidad sobre todo en países en vías de desarrollo por las razones antes mencionadas. (Bennett et al., 2020)

El tercer grupo es el uso de la teledetección para la predicción del rendimiento del cultivo, esta aplicación interesa tanto al productor como a distintos entes gubernamentales y privados como accionistas, corredores de bolsa, y aseguradoras de cultivo (Weiss et al., 2020). Una predicción confiable provee información importante para los mercados, tanto para comparar con otras regiones como para realizar acciones de contingencia como de ayuda humanitaria, debido a que esta aplicación se basa en el uso de imágenes multiespectrales tomadas por sensores satelitales, las mismas

limitaciones con respecto a la resolución espectral y espacial aplican en esta área, por esto, la aplicación está restringida principalmente a grandes extensiones de cultivo (Paliwal & Jain, 2020). La metodología principal utilizada es la de la correlación del pico de un índice de vegetación simple como el del NDVI con el rendimiento, este pico puede ser anticipado utilizando una metodología sencilla como la de los grados día acumulados (Zhang et al., 2019). Esta y otras metodologías tienen limitantes y un rango de variación alta entre la predicción y el dato real (Weiss et al., 2020). Alguna de las soluciones a los retos antes mencionados es la combinación de imágenes de alta resolución espacial pero baja resolución temporal con imágenes con menor resolución espacial y mayor resolución temporal utilizando modelos de corrección, además, de calibraciones de los modelos matemáticos con muestreos del rendimiento real (Paliwal & Jain, 2020 & Weiss et al., 2020).

El cuarto grupo es el monitoreo del cultivo para optimizar el rendimiento; este engloba una amplia gama de aplicaciones como la detección de malezas, plagas y enfermedades, la determinación del contenido de nitrógeno y agua, el sobrecalentamiento, la fenología, la biomasa, el índice de área foliar, la altura, la fecha ideal de cosecha, entre otros (Peteinatos et al., 2016; Weiss et al., 2020). Aplicaciones como la detección de malezas requieren de imágenes de muy alta resolución ya que es preciso, diferenciar entre el cultivo y las malezas, además, cuanto mayor es la densidad de siembra más se dificulta la tarea, por esto, es necesario utilizar drones (Hu et al., 2021). El uso de drones con sensores multispectrales provee de una mayor resolución espacial y temporal, esto es relevante debido a que el productor necesita conocer la información en el momento adecuado para tomar medidas correctivas lo más pronto posible (Khanal et al., 2020). En los últimos 20 años el uso de la teledetección para el manejo del cultivo ha aumentado considerablemente y ciertamente han sido efectivos en la toma de decisiones en distintas etapas fenológicas de varios cultivos (Khanal et al., 2020).

El último grupo de aplicaciones es el de la teledetección en la agricultura para servicios ecosistémicos. Los sistemas agro productivos no solo tienen la función de producir alimento, fibras y combustible, sino que también están involucrados en la

preservación de mantos acuíferos, del suelo, captura de carbono y conservación de la biodiversidad (Weiss et al; 2020). Las diferentes labores agrícolas juegan un papel importante en el medio ambiente, la labranza y la rotación de cultivos de acuerdo con las condiciones pueden ayudar a conservar o por el contrario a degradar el recurso suelo; la aplicación de agroquímicos también puede afectar de manera negativa los mantos acuíferos y la biodiversidad (Power, 2010). Prácticas de riego y de protección de cultivos como el uso de canales y barreras vivas, afectan la forma y la dirección del agua y del viento junto con otros materiales llevados por estos como el polen, residuos de agroquímicos o suelo (Power, 2010). La teledetección junto con los sistemas de información geográfica, pueden ser una herramienta importante en la medición de estos servicios ecosistémicos, por ejemplo, mediante modelos digitales de elevación aportan información sobre la pendiente, las líneas preferenciales de escorrentía o cambios en la topografía de la zona a través del tiempo, zonas de vida o mantos acuíferos potencialmente afectados por la actividad productiva, la erosión, la producción de biomasa y alimentos, la fijación de carbono, entre otros, los cuales pueden ser identificados mediante las hojas cartográficas de la región y estimados mediante técnicas de teledetección (De Araujo Barbosa et al., 2015; del Río-Mena et al., 2020)

3.5 Aplicaciones de la teledetección en arroz y otros cultivos

A pesar de que en la agricultura se utiliza fertilizante nitrogenado en grandes cantidades, la eficiencia de la aplicación de este es baja por lo que siempre es necesario realizar refuerzos; el uso de imágenes multiespectrales para aplicar el nitrógeno en el momento y área necesaria, puede aumentar la efectividad de la aplicación de este (Dos Santos et al., 2020). En un estudio realizado en el estado de Arkansas por Dos Santos et al. (2020) tuvieron como objetivo evaluar el uso de la intensidad del verdor del dosel determinado por el índice de vegetación DGCI, obtenido a partir de imágenes aéreas como una guía para la decisión de la fertilización nitrogenada en el cultivo de maíz. Se evaluó la utilidad del índice DGCI para evaluar el estado del contenido de nitrógeno en la planta, al establecerse un total de ocho campos de muestreo y se recolectaron las imágenes en los estadios V10, V12 y VT, en distintas condiciones lumínicas. Las mediciones de DGCI predijeron la concentración de nitrógeno foliar y el rendimiento

de grano de forma precisa; por lo que el estudio proveyó un marco de referencia para estimar el contenido de nitrógeno en los estados tempranos y tardíos de desarrollo del cultivo, debido a que los autores de este estudio encontraron que el DGCI tuvo buenas correlaciones con el rendimiento y con el contenido de nitrógeno.

Determinar la cantidad de nitrógeno a aplicar depende de muchos factores, en el cultivo de arroz comúnmente se realizan dos aplicaciones de fertilizante nitrogenado, la segunda aplicación depende de la eficiencia de la primera (Foster et al., 2017). Es por esto que el uso de sensores de radiación para determinar la salud del cultivo puede ser una herramienta efectiva para dosificar el nitrógeno según el caso, que podría generar un ahorro de dinero o un aumentando el rendimiento. Foster et al., (2017), evaluaron el uso del manejo basado en sensores como guía en la decisión de la aplicación de nitrógeno, se compararon los rendimientos y la cantidad de nitrógeno aplicado entre los distintos tratamientos y el manejo tradicional, los resultados indicaron que el uso del sensor para realizar la fertilización aumentó la eficiencia del uso del nitrógeno y establecieron una dosis óptima para dichas condiciones.

El uso de drones especiales para la captura de imágenes multiespectrales en cultivos muy extensivos como los de granos básicos y pastos puede ser muy costoso, por lo que evaluar alternativas que puedan abarcar áreas mayores con una mayor autonomía y un menor costo es importante para aumentar la eficiencia de esta tarea. Guan et al., (2019), evaluaron la operatividad y la eficiencia de los vehículos aéreos no tripulados a distintas alturas y el uso de imágenes multiespectrales para predecir el rendimiento. Se evaluó el uso de dos modelos de drones pequeños a los que se les adaptó una cámara con sensores multiespectrales, con estos se realizaron vuelos en 120 campos para un total de 77 ha, determinado la altura de vuelo ideal para obtener la eficiencia máxima, también se evaluó el NDVI y se correlacionó con el rendimiento de los cultivos de pasto y arroz. Se encontró que la altura máxima de vuelo para una mayor eficiencia del dron fue de 100 metros para cubrir 19,8 ha en 10 min, además, hubo una correlación entre el rendimiento y el NDVI de ambos cultivos de 0,6 y 0,8 respectivamente.

El cultivo de arroz es extensivo y la variabilidad en términos de rendimiento dentro de una población es importante, por esto el monitoreo puede ser complicado. Además, la nivelación del terreno es crucial para mantener una lámina de agua homogénea a lo largo del lote con el propósito de tener un desarrollo y por lo tanto un rendimiento y manejo homogéneo. González-Betancourt & Mayorga-Ruíz, (2018) evaluaron las imágenes aéreas y el NDVI como herramientas para la supervisión del arroz a gran escala. En el trabajo utilizaron el NDVI para identificar problemas en el desarrollo del cultivo y se encontró que en la etapa del desarrollo de la panícula mediciones de NDVI menores a 0,8 se debían a problemas de nivelación, estrés hídrico y diferencias en el estado de las plantas. Se encontró una alta correlación en esta etapa con el rendimiento, número de panículas por metro cuadrado y el peso de 1 000 granos. El trabajo establece un indicio de una época de muestreo en la que es probable que se encuentren buenas correlaciones con variables de rendimiento que podrían evaluarse.

Predecir el rendimiento durante etapas tempranas del crecimiento es importante para el diagnóstico inicial y el uso de medidas correctivas sobre todo nutricionales. Zhang et al., (2019) tuvieron como objetivo evaluar los datos de índices espectrales obtenidos usando el sensor RapidScan CS-45 durante el crecimiento del arroz y construir un modelo dinámico utilizando los índices de vegetación, también desarrollaron un algoritmo de predicción de rendimiento del grano de arroz basado en este modelo. En este estudio se utilizaron distintas dosis de fertilización entre 0 y 400 kg N ha⁻¹ y tres variedades japónicas de arroz, se recolectaron distintos índices de vegetación a lo largo del desarrollo del cultivo para realizar un modelo matemático, después se realizó un análisis de correlación entre el rendimiento, el índice de área foliar y acumulación de nitrógeno en la planta y los distintos índices de vegetación. El índice de diferencia normalizado de borde rojo (NDRE) [2] fue el más prometedor, con un índice de determinación (R²) mayor a 0,9. A continuación la fórmula del NDRE:

$$NDRE = \frac{(\text{Borde rojo}-R)}{(\text{Borde rojo}+R)} \quad (2)$$

El monitoreo de cultivos a gran escala es de interés para diversos grupos. El conocer la cantidad de cultivo y la edad de este es importante por motivos de seguridad alimentaria y proyección de fechas de cosecha y futuros cambios en el agroecosistema. Nuarsa et al; (2011) desarrollaron el índice de vegetación del crecimiento del arroz (RGVI) [3] para monitorear la edad del cultivo de arroz, para ello utilizaron imágenes satelitales del Lansat ETM+. Al correlacionar la edad del cultivo con los distintos índices de vegetación, entre ellos el RVI, TVI, SAVI, IPVI, DVI, NDVI y RGVI. Con el RGVI obtuvieron un R^2 de 0,9 superior al de los otros, seguido por el TVI [4] con un R^2 de 0,87. Esta investigación aportó un nuevo índice que potencialmente tendrá otras aplicaciones en el monitoreo del cultivo de arroz. Debido a restricciones tecnológicas por las bandas utilizadas, el uso del índice es exclusivo a la teledetección utilizando imágenes satelitales. Estas son las fórmulas de los índices utilizados:

$$RGVI = 1 - \frac{(450-520)nm+(630-690)nm}{(770-900)nm+(1550-1750)nm+(2080-2350)nm} \quad (3)$$

$$TVI = \sqrt{NDVI + 0,5} \quad (4)$$

Al fusionar datos de la altura de la planta obtenidos con un sensor LiDAR e índices de vegetación obtenidos con un espectrofotómetro (sensor de mano el cual posee un sensor hiperespectral) para determinar la biomasa del cultivo de cebada. Tilly et al., (2015) obtuvieron que la combinación de los datos resultó en un R^2 de 0,85, adicionalmente, mediante regresión de algunos de los índices de forma individual también se obtuvieron valores de R^2 altos (0,7 a 0,87). La investigación utilizó índices de vegetación que se conoce tienen buena correlación con la biomasa y el índice de área foliar (GnyLi [5], NDVI [1], NRI [6], RDVI [7], REIP [8] y RGBVI [9]). Se probaron modelos de regresión lineal y exponencial entre los índices y la biomasa seca y fresca, los mejores resultados fueron los resultantes de modelos de regresión para los índices GnyLi y NRI, para los demás índices el R^2 fue bajo (0,3 a 0,6). Sin embargo, al realizar los modelos de forma multivariable entre los índices, biomasa y altura de planta hubo un aumento significativo en el valor del coeficiente de determinación de

todos los índices de vegetación. Los índices de vegetación que mejor resultado dieron fueron los que utilizaron bandas que por lo general, no están disponibles en sensores comerciales de drones o satelitales, no obstante, los resultados obtenidos fueron para el cultivo de cebada, es posible que los índices sean apropiados para otros cultivos similares como el del arroz. A continuación, se presentan las fórmulas de los índices utilizados en el estudio:

$$GnyLi = \frac{(R900 \times R1050 - R955 \times R1220)}{(R900 \times R1050 + R955 \times R1220)} \quad (5)$$

$$NRI = \frac{(R874 - R1225)}{(R874 + R1225)} \quad (6)$$

$$RDVI = \frac{(\text{Infrarrojo} - \text{Rojo})}{(\sqrt{\text{Infrarrojo} + \text{rojo}})} \quad (7)$$

$$REIP = 700 + 40 * \frac{((R670 + R780)/2) - R700}{R740 - R700} \quad (8)$$

$$RGBVI = \frac{(Rverde^2 - Razu \times Rrojo)}{(Rverde^2 + Razu \times Rrojo)} \quad (9)$$

Estas y muchas otras aplicaciones de la teledetección son utilizadas a diario en países desarrollados para facilitar la adquisición de información con mayor precisión, para la toma de decisiones que aumenten la sostenibilidad del agroecosistema, el rendimiento y la rentabilidad de los cultivos.

3.6. Determinación del Índice de Área Foliar

El Índice de Área Foliar (IAF) se define como el total de área foliar por un solo lado por unidad de superficie de suelo (Liang & Wang, 2020), como se muestra en la siguiente fórmula:

$$IAF = \frac{\text{área foliar (m}^2\text{)}}{\text{área de suelo (m}^2\text{)}}$$

Determinar la cantidad de área foliar en un área definida es crítico para cuantificar la cantidad de fotosíntesis, evapotranspiración (cantidad de agua que vuelve a la atmósfera resultado de la evapotranspiración y transpiración de la vegetación) intercepción de precipitación y un parámetro esencial para el cambio climático (Fang et al., 2019).

Existen distintas formas de medir el IAF y se pueden clasificar en medidas directas e indirectas (Fang et al., 2019). Las mediciones directas destructivas consisten básicamente en cosechar todas las hojas dentro de un área de suelo conocida y después medir el área foliar utilizando un escáner o un medidor de área foliar como el Li-3000 (Liang & Wang, 2020). Otra forma similar, pero no destructiva es mediante la colocación de trampas para la caída de hojas, esto es viable sobre todo para especies de árboles que presentan pérdida total del follaje en una época del año (Liang & Wang, 2020). En el caso de querer agilizar la labor es posible utilizar un método gravimétrico, mediante relaciones entre la cantidad de materia seca y el área foliar (Patil et al., 2018).

El método indirecto consiste en inferir el IAF mediante la observación de otras variables más fáciles de medir y que obviamente están relacionadas (Patil et al., 2018). El método alométrico estima el IAF mediante regresiones simples empíricas de otros parámetros similares más fáciles de medir, como la edad, altura, largo y ancho de la hoja, entre otros, se ha observado que, al agregar parámetros como la altura del dosel o la cobertura del mismo, así como los grados día acumulados o la temperatura del aire aumentan la precisión de estos modelos (Fang et al., 2019). Otro método indirecto muy utilizado es el uso de sensores ópticos, estos miden la transmitancia de luz del dosel para luego convertirla a IAF mediante la Ley de Beer-Lambert:

$$LAI = -Ln(Qi/Q0)/K$$

En donde K es el coeficiente de extinción, Qi es la luz PAR debajo del dosel y Q0 la radiación PAR sobre el dosel. Usualmente se asume que el grado de inclinación de las hojas es esférico y que las hojas están distribuidas de manera aleatoria en el dosel (Liang & Wang, 2020). Uno de los equipos más comúnmente utilizados para este método son el analizador del dosel de plantas LAI-2000 o 2200c y el ceptómetro LP-80 (Fang et al., 2019).

El LAI-2000 se basa en la combinación de las ecuaciones de Beer-Lambert y Miller para obtener el IAF sin necesitar el índice de distribución de las hojas. Sin embargo, este aparato presenta errores asociados a que solo posee cinco tipos de ángulos cenital con respecto al sol, y al no tomar en cuenta el grado de inclinación de las hojas, por lo que tiende a sobreestimar el IAF de plantas con arquitecturas de la hoja de tipo plana, o a subestimarlo para las plantas con arquitecturas de hojas erectas (Geng et al., 2021). Debido a estas limitaciones este equipo es recomendado para doseles con hojas de arquitecturas de tipo esféricas y en días nublados o al inicio o final del día (Liang & Wang, 2020).

El LP-80 también se basa en las ecuaciones de Beer-Lambert, sin embargo, este no obvia el parámetro de distribución de las hojas ni está limitado por un número determinado de ángulos cenitales con respecto al sol. El equipo es afectado principalmente por dos parámetros, la cantidad de luz PAR disponible y por el parámetro de distribución de las hojas (Pokovai & Fodor, 2019), el ángulo cenital es calculado automáticamente con la hora del día y la ubicación. Pokovai & Fodor (2019), concluyeron que una cantidad de luz PAR inferior a $1700 \mu\text{mol m}^{-2} \text{s}^{-1}$ resulta en valores subestimados de IAF, estos obtuvieron un valor del coeficiente de determinación de 0,86 entre el IAF estimado y mediciones directas. No se encontraron investigaciones respecto al valor del parámetro de distribución de las hojas, el fabricante recomienda un valor de 1 para cultivos con arquitectura de las hojas esférica, un 3 para cultivos con arquitectura plana y un 0,7 para cultivos de arquitectura erecta.

Por último, una forma muy práctica de medir el IAF es mediante la reflectancia de la luz del cultivo, esta puede medirse utilizando sensores remotos o un

espectrorradiómetro de campo, al utilizar modelos de regresión o mediante inteligencia artificial. Correlacionando índices de vegetación con valores de IAF. Este método presenta muchas ventajas como es el mapeo y monitoreo de grandes extensiones de cultivos o bosques, menor costo y mayor frecuencia de muestreo, y la no destrucción de material vegetal sobre todo si se trata de áreas protegidas (Liang & Wang, 2020).

4. Metodología

4.1. Localización

El trabajo se realizó en la sección 8 del lote 20 de la Estación Experimental agrícola Fabio Baudrit Moreno ubicada en La Garita de Alajuela (coordenadas: 10°0' 25,42" Norte, 84°15' 56,77" Oeste).

4.2. Material Experimental

Se utilizaron semillas de arroz de las variedades Lazarroz y Senumisa 20, proporcionadas por la empresa Hacienda el Pelón de la Bajura.

4.3. Procedimiento general

Se establecieron dos parcelas de arroz en secano al inicio de la época lluviosa, una por variedad, con una dimensión de 180 m² cada una (Figura 1). Durante el ciclo se evaluaron la reflectancia y el índice de área foliar (IAF) de manera indirecta (área foliar por unidad de área de superficie de suelo) en un área de 20 m² del centro de la parcela. Las muestras para la calibración del ceptómetro se tomaron del área circundante, excepto un borde de 1m de ancho.



Figura 1. Parcelas de arroz en secano de las variedades Senumisa 20 (izquierda) a 100 días después de la emergencia y Lazarroz (derecha) a 70 días después de la emergencia, en la Estación Experimental Agrícola Fabio Baudrit Moreno durante la época lluviosa.

La densidad de siembra fue de 150 kg ha¹ y la fertilización consistió en una aplicación de 150(N)-50(P)-100(K) kg.ha¹ (Arias-Badilla et al., 2020). Además, se realizó un muestreo y análisis químico completo de suelos (Anexo 3), además de uno foliar en la etapa de hoja bandera (Anexo 2) para compararlos con los valores óptimos (Anexo 1) para realizar correcciones en la fertilización en caso de que fuera necesario.

Semanalmente, se llevaron a cabo al menos dos monitoreos de insectos, patógenos y arvenses. La estrategia de manejo de plagas fue preventiva, con aplicaciones semanales de *Bacillus thuringiensis* y *Trichoderma* sp, en caso de un aumento en la severidad o incidencia (según sea el caso) de alguna plaga se utilizaron agroquímicos. Para evitar la competencia con malezas, el manejo de estas consistió en la aplicación del herbicida preemergente pendimetalina (0,77 L ha¹) después de la siembra, y el postemergente propanil (2,88 L.ha¹) según los resultados de los monitoreos de malezas, junto con controles manuales.

También se registraron las temperaturas máximas y mínimas durante el ciclo desde la siembra por medio de una estación meteorológica, para el cálculo de los grados día acumulados (GDA) con la siguiente fórmula (Temp. Base = 10°C) (Velázquez et al., 2015):

$$GDA = \sum ((Temp. Máx + Temp. Mín)/2) - Temp. Base$$

Durante el ciclo, se midió la reflectancia del cultivo con el uso del espectrorradiómetro Fieldspec 4, con el cual se obtiene la firma espectral (reflectancia del cultivo desde los 350 a los 2500 nm), para posteriormente obtener la reflectancia promedio para el azul (385 a 415 nm), verde (535 a 565 nm), rojo (655 a 685 nm), borde rojo (715 a 745 nm) e infrarrojo cercano (785 a 815 nm), para obtener valores con una resolución espectral similar a la de las cámaras de drones y satélites, con el propósito de calcular los índices de vegetación: de Amplio Rango Dinámico (WDRVI por sus siglas en inglés) [10], de Diferencia de Proporción (RDVI por sus siglas en inglés) [7], de Proporción (RVI por sus siglas en inglés) [11] y el Rojo-Verde-Azul (RGBVI según sus siglas en inglés) [9]. De acuerdo con Tilly et al., (2015) y Xue y Su

(2017), estos índices tienen buena correlación con el índice de área foliar y con la biomasa, parámetros que están altamente correlacionados con la productividad (Hirooka et al., 2017 y Tilly et al., 2015). También se incluyeron el Índice de Diferencia Normalizada de Borde Rojo (NDRE por sus siglas en inglés) [2] y el Índice de Vegetación Transformada (TVI por sus siglas en inglés) [4], que tienen buena correlación con el rendimiento (Zhang et al., 2019) y la edad del cultivo de arroz respectivamente (Nuarsa et al., 2011).

$$WDRVI = \frac{(\alpha \text{Infrarrojo} - \text{Rojo})}{(\alpha \text{Infrarrojo} + \text{Rojo})} \quad (10)$$

Donde α es igual a 0,2, valor encontrado como el más apropiado (Xue & Su, 2017).

$$RVI = \frac{\text{Infrarrojo}}{\text{Rojo}} \quad (11)$$

La reflectancia y el índice de área foliar se midieron semanalmente, a partir de los 15 días después de emergencia. La muestra consistió en 10 puntos fijos seleccionados de manera aleatoria hasta la etapa de hoja bandera.

El índice de área foliar fue medido de manera indirecta utilizando el ceptómetro de mano LP-80, a medio día con una luz PAR de alrededor de $2000 \mu\text{mol m}^{-2} \text{s}^{-1}$. Además, se realizó una medición directa semanalmente de un área de $0,10 \text{ m}^2$, para obtener el índice de área foliar real y el valor del parámetro de distribución de las hojas (χ) para cada semana.

La determinación del área foliar para obtener el IAF real se realizó utilizando el medidor de área foliar LI-3100C, para esto se recolectaron todas las plantas en el área de $0,10 \text{ m}^2$ en un balde con agua, posteriormente se separaron todas las hojas del tallo para procesarlas en el LI-3100C y calcular el IAF.

Una vez conocido el IAF real, en un área cercana a donde se tomó la muestra destructiva mediante prueba y error se encontró el valor de χ en el ceptómetro, con el

cual se obtuviera una estimación de IAF similar. Este χ se utilizó para estimar el IAF de los 10 puntos de muestreo (Anexo 4 y 5).

Al finalizar el ciclo del cultivo, el rendimiento de las parcelas se midió utilizando el promedio de cinco áreas de 3m^2 cada una dentro del área útil. La medición del rendimiento consistió en el número de panículas por unidad de superficie, el peso promedio de mil granos y el rendimiento en kg ha^{-1} del grano en granza seco (aproximadamente 13% de humedad) y limpio. Si el rendimiento promedio alcanzó al menos el promedio nacional para el periodo pasado (2019-2020) de 4,5 t, se consideró que la parcela puede utilizarse como referencia.

Además, se realizó un vuelo en la etapa de inicio de emergencia de panícula para correlacionar los valores de los índices y las bandas espectrales de las cinco áreas mencionadas con el rendimiento. Se utilizó el dron DJI Matrice 200 al que se le adaptó la cámara Altum-PT de Micasense, la captura de imágenes se realizó a una altura de 80 m con un traslape del 80%.

El ortomosaico se realizó mediante el programa PIX4Dmapper y las imágenes se analizaron utilizando el software Qgis. Para delimitar las áreas en las que se midió el rendimiento se tomó una foto utilizando el dron DJI Spark después de la cosecha. La foto fue ortorectificada utilizando la herramienta de georreferenciador tomando el ortomosaico como referencia. Debido a que el dosel estaba completamente cerrado cuando se tomó la foto con la cámara multispectral con la herramienta estadística zonal se obtuvo el promedio de reflectancia de las bandas para cada área, el tamaño de la muestra para las áreas de la variedad Lazarroz fue de $1863,4 \pm 211,3$ píxeles. En el caso de la variedad Senumisa 20, el dosel no cerró por completo por lo que se realizó un buffer de 10 cm para cada hilera contenida en el área de medición y se extrajeron los valores promedios de las bandas en el buffer, el tamaño de muestra fue de $1127,8 \pm 124,2$ píxeles.

El cálculo de los índices de vegetación se realizó con las mismas fórmulas que con el espectrorradiómetro utilizando los promedios de las bandas obtenidos del análisis de las imágenes.

4.5 Diseño experimental

Al ser una investigación descriptiva esta no posee tratamientos y no requiere de un diseño experimental.

4.6 Análisis estadísticos de datos

Se realizaron análisis de correlación de Pearson entre los valores de los índices de vegetación y los de las bandas utilizadas (Azul, Verde, Roja, Borde roja e Infrarroja) con respecto a los del índice de área foliar. Los promedios semanales y la variación de los índices de vegetación o bandas que tuvieron un buen coeficiente de correlación de Pearson ($r \geq 0,6$ o superior) fueron considerados valores de referencia.

Además, se elaboraron y presentaron modelos de regresión con buen coeficiente de determinación ($R^2 > 0,7$) entre los valores de los índices de vegetación y de las bandas espectrales con respecto al índice de área foliar.

Se realizaron análisis de correlación de Pearson entre los valores de los índices de vegetación y los de las bandas utilizadas (Azul, Verde, Roja, Borde roja e Infrarroja) obtenidos con la cámara Altum-PT con respecto a los del rendimiento.

Al finalizar se establecieron los valores de referencia de los índices de vegetación con mejor correlación para cada variedad, al graficar dichos valores contra los grados día acumulados. Además, se construyeron modelos matemáticos de regresión entre los índices de vegetación y los datos de índice de área foliar.

El análisis estadístico de los datos se realizó con el programa R software.

5. Resultados

5.1. Análisis de correlación de Pearson entre bandas espectrales e índices de vegetación con respecto al IAF.

El análisis de correlación de Pearson (Cuadro 1), demostró correlaciones negativas para todas las bandas espectrales excepto para la Infrarrojo cercano. De las bandas espectrales utilizadas, las que tuvieron buena correlación fueron la Azul, Verde y Roja para la variedad Lazarroz, y la Verde y Roja para la Senumisa 20. Todos los índices de vegetación tuvieron correlaciones positivas excepto el RGBVI para la variedad Senumisa 20. Todos los índices tuvieron buena correlación con excepción del RGVI y el RDVI, destacando el NDRE, siendo el índice con mayor correlación para ambas variedades con un r de 0,93 y 0,88 para Senumisa 20 y Lazarroz respectivamente.

Cuadro 1. Coeficientes de correlación de Pearson (r) entre las bandas espectrales y los índices de vegetación contra el IAF según la variedad de arroz.

Variedad	Bandas espectrales					Índices de vegetación					
	Azul	Verde	Roja	Borde Rojo	Infrarrojo cercano	WDRVI	RDVI	RVI	RGBVI	NDRE	TVI
Senumisa 20	-0,48	-0,72	-0,68	-0,50	0,24	0,71	0,42	0,68	-0,41	0,93	0,71
Lazarroz	-0,73	-0,73	-0,80	-0,20	0,50	0,74	0,6	0,81	0,24	0,88	0,74

5.2. Análisis descriptivo del comportamiento de las bandas espectrales con respecto a la suma térmica.

Las bandas con buena correlación (superior a 0,7) con el índice de área foliar para la variedad Senumisa 20, se comportaron de manera similar durante la etapa vegetativa, los valores disminuyeron con respecto a la suma térmica, con un aumento a los 898 °C y en la última medición a los 1162,89 °C (Figura 2). Con respecto a la variación de los datos, esta fue similar para ambas bandas siendo mayor al inicio del ciclo y disminuyendo hacia el final de la etapa vegetativa.

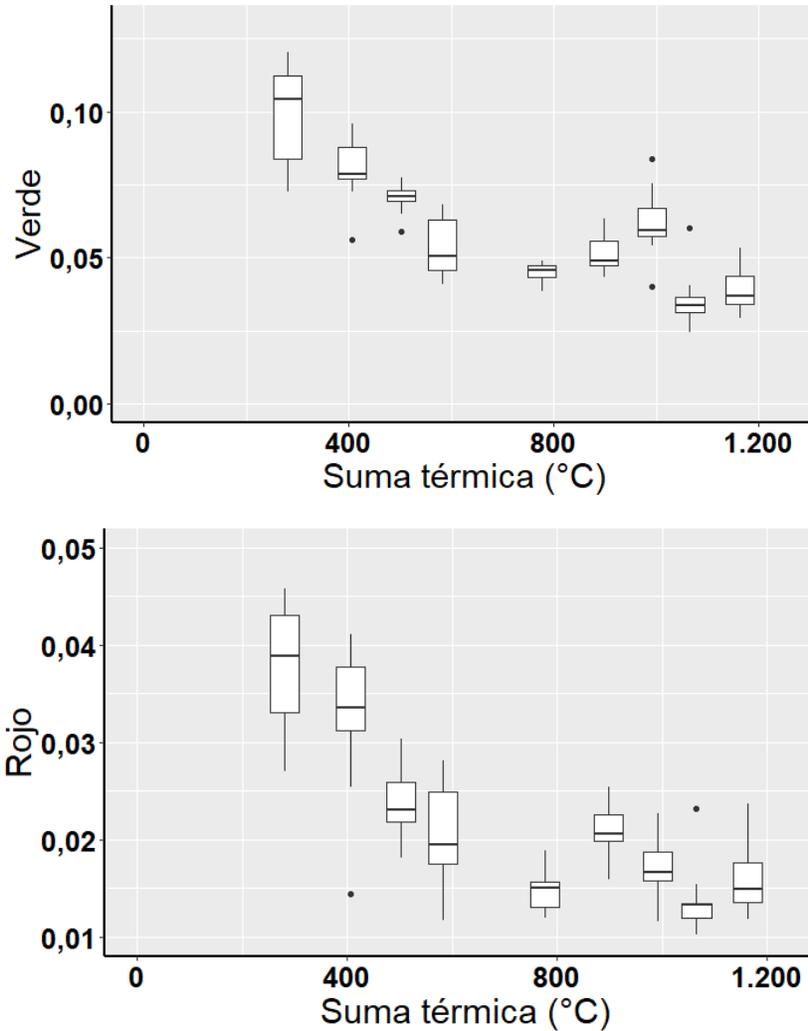


Figura 2. Diagramas de cajas con el promedio, cuartil inferior y superior de la reflectancia de las bandas verde (550 ± 15 nm) y roja (670 ± 15 nm), con respecto a la suma térmica para la variedad Senumisa 20

Para la variedad Lazarroz las bandas roja y azul se comportaron de manera similar durante el ciclo de cultivo, los valores fueron disminuyendo con respecto a la suma térmica, con un aumento a los 979 °C (Figura 3). La banda verde se comportó de manera similar, en general los valores de reflectancia disminuyeron con respecto a la suma térmica con un aumento a los 545 °C y 979 °C. Al igual que con la variedad Senumisa 20, la variación de los datos fue similar para las tres bandas, siendo mayor al inicio del ciclo y disminuyendo hacia el final de la etapa vegetativa.

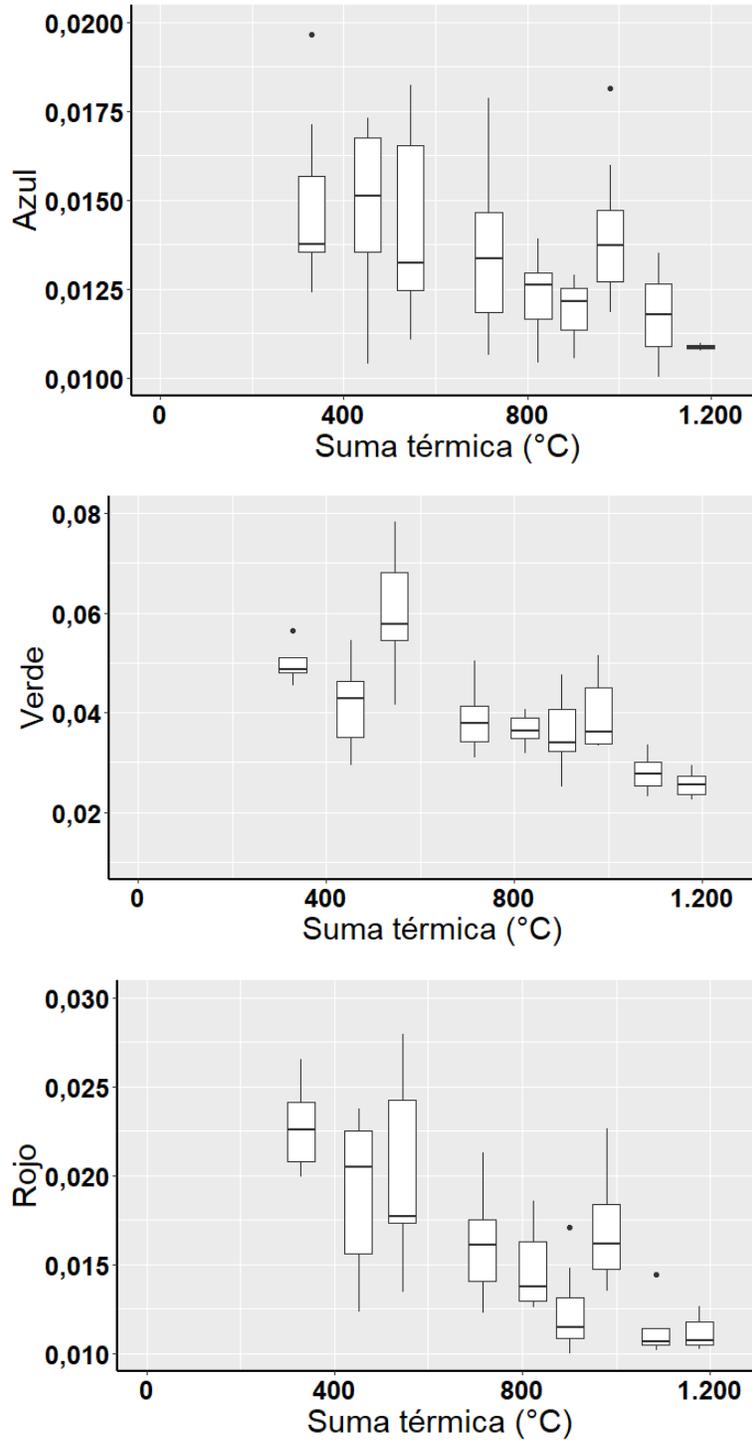


Figura 3. Diagramas de cajas con la mediana, cuartil inferior y superior de la reflectancia de las bandas azul (400 ± 15 nm), verde (550 ± 15 nm) y roja (670 ± 15 nm), con respecto a la suma térmica para la variedad Lazarroz

5.3. Análisis descriptivo del comportamiento de los índices de vegetación con respecto a la suma térmica.

Para la variedad Senumisa 20, los índices de vegetación con buena correlación con el IAF tuvieron valores en general crecientes con respecto a la suma térmica. Sin embargo, todos los índices con buena correlación (excepto por el NDRE), disminuyeron a los 898,73 °C y 1066° C (Figura 4 y 5). El NDRE fue el único índice con valores siempre crecientes. La variación de los datos para todos los índices fue similar durante la etapa vegetativa excepto para el WDRVI que fue en disminución.

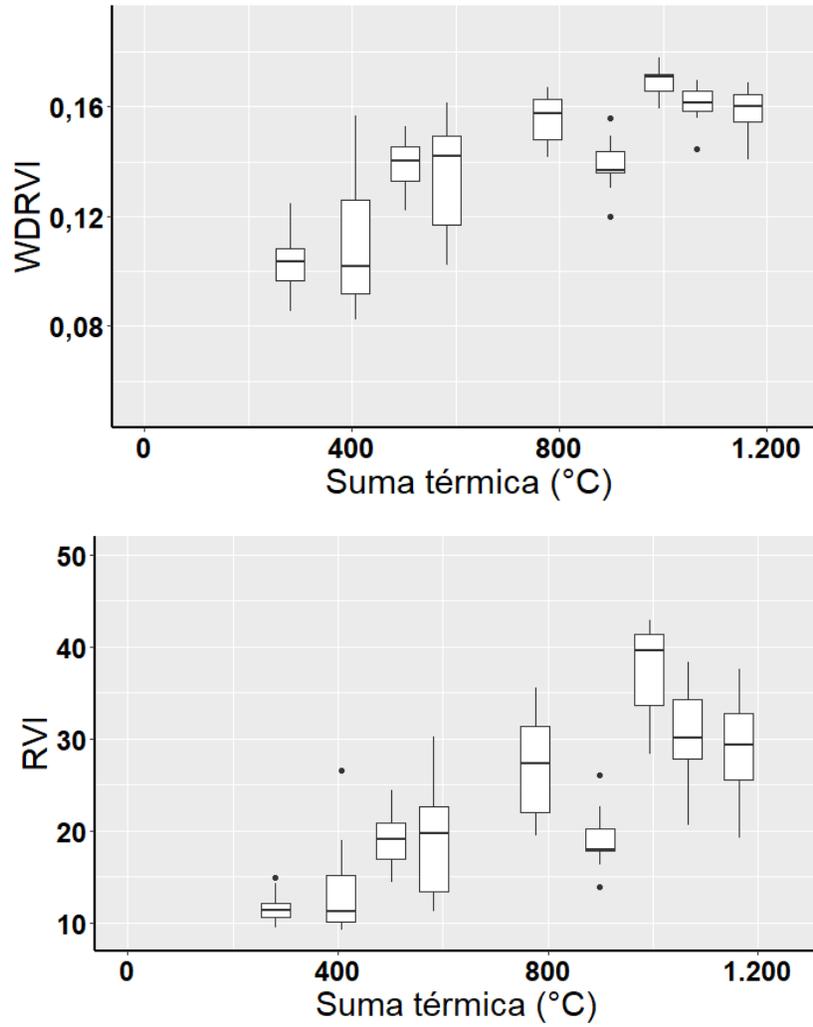


Figura 4. Diagramas de cajas con la mediana, cuartil inferior y superior de los Índices de vegetación WDRVI y RVI con respecto a la suma térmica de la variedad Senumisa 20

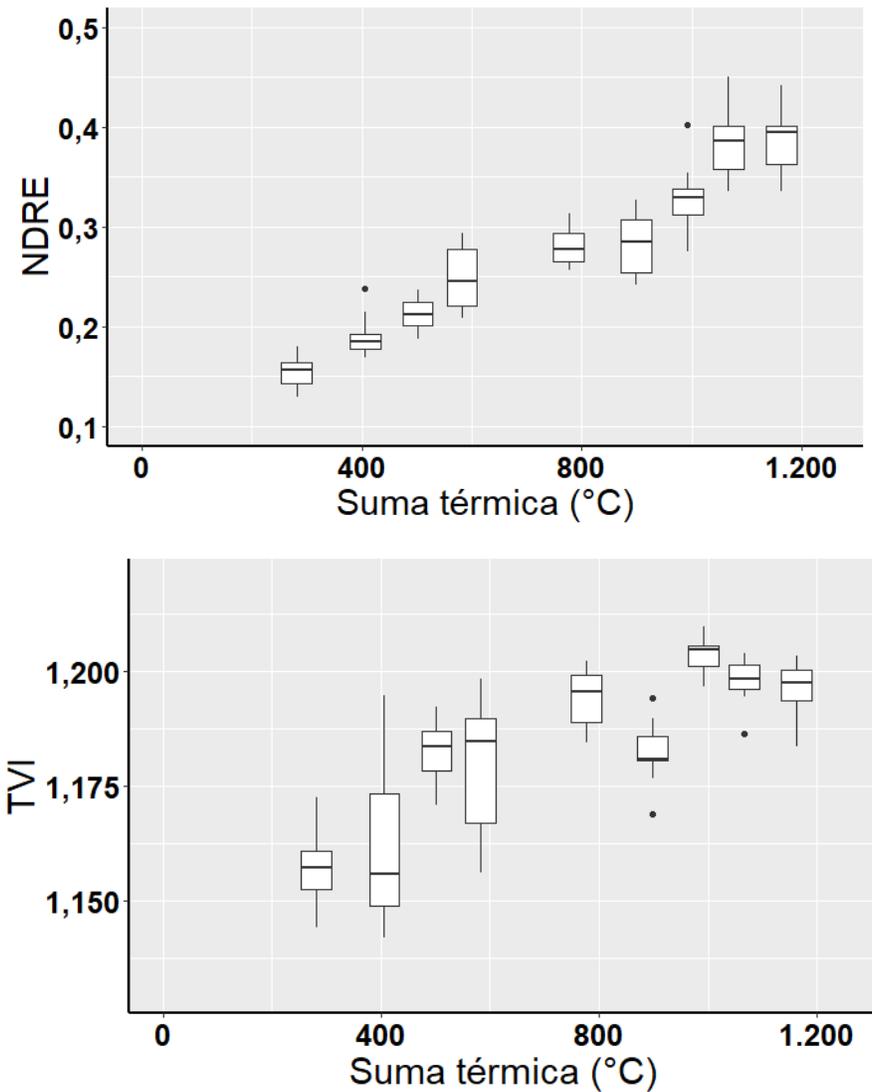


Figura 5. Diagramas de cajas con la mediana, cuartil inferior y superior de los Índices de vegetación NDRE y TVI, con respecto a la suma térmica de la variedad Senumisa 20

Para la variedad Lazarroz, los índices de vegetación con buena correlación con el IAF tuvieron valores en general crecientes con respecto a la suma térmica. Sin embargo, estos (excepto por el NDRE), disminuyeron a los 715 °C y 979° C (Figura 6 y 7). El NDRE fue el único índice con valores siempre crecientes. La variación de los datos para todos los índices fue en disminución con respecto a la suma térmica, excepto para el RVI que fue siempre consistente excepto a los 901° C.

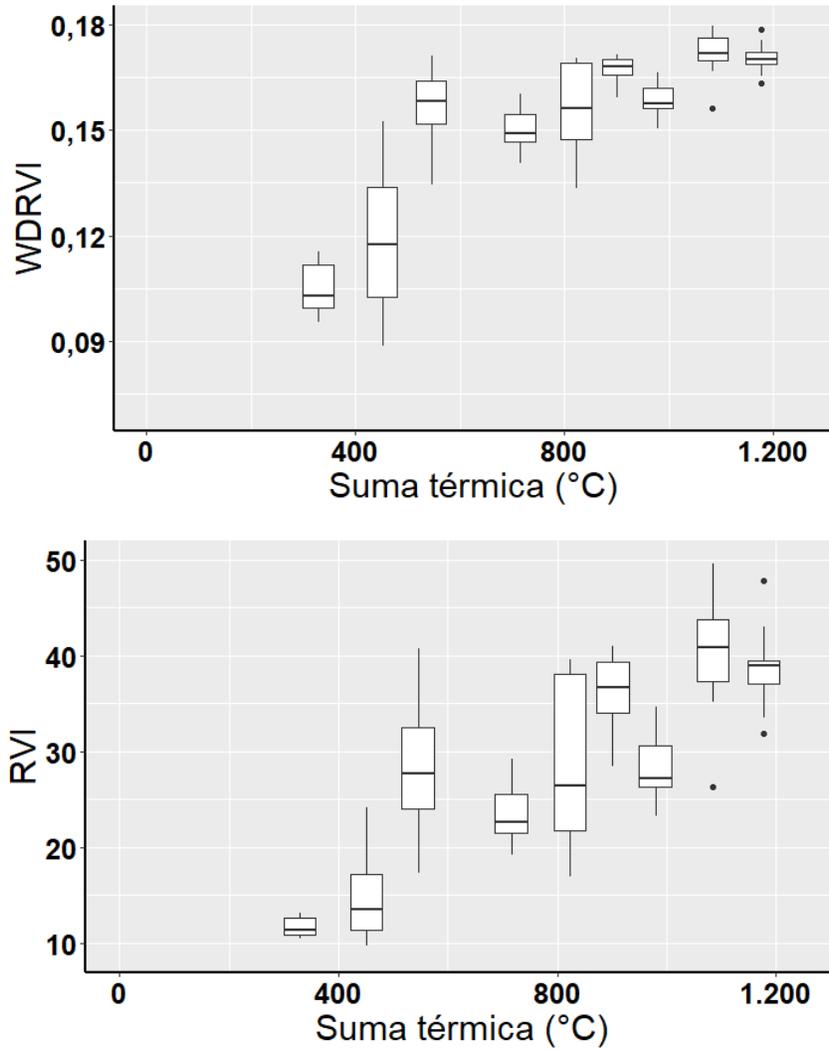


Figura 6. Diagramas de cajas con la mediana, cuartil inferior y superior del Índices de vegetación WDRVI y RVI con respecto a la suma térmica de la variedad Lazarroz

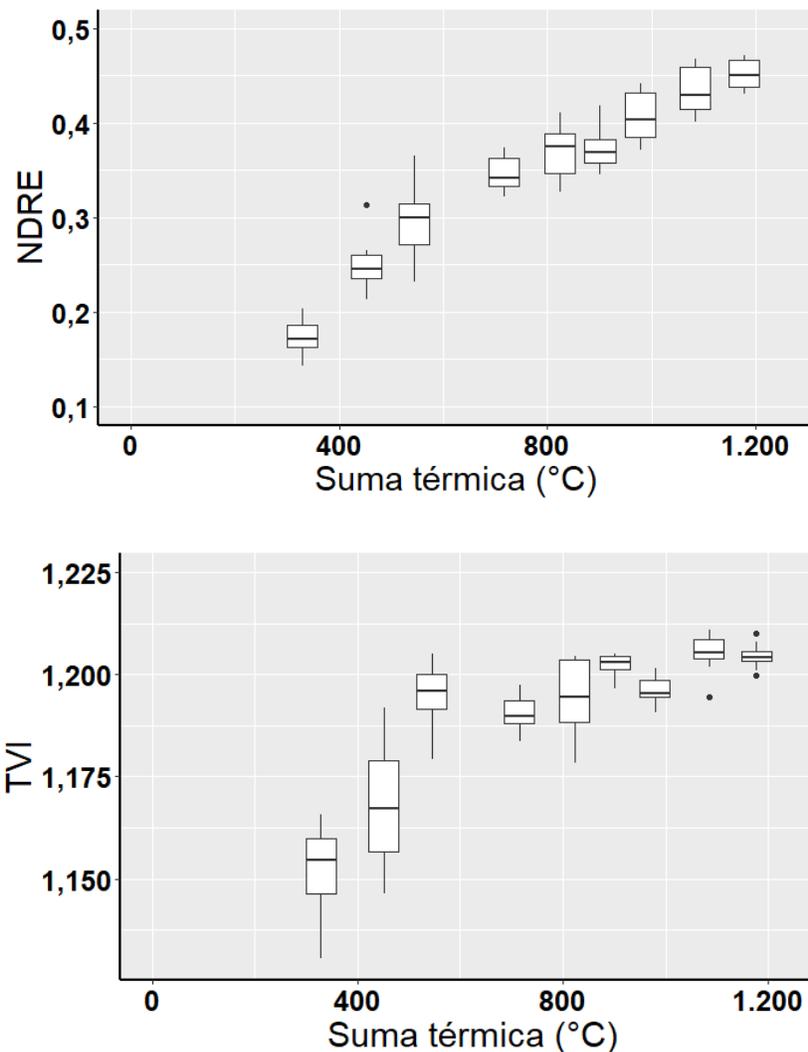


Figura 7. Diagramas de cajas con la mediana, cuartil inferior y superior del Índices de vegetación NDRE y TVI con respecto a la suma térmica de la variedad Lazarroz

5.4. Valores de referencia de las bandas e índices de vegetación y su variación.

Los valores mínimos de reflectancia para las bandas verde y roja fueron de 0,036 (factor de reflectancia en base 1, quiere decir que reflejó 3,6% de la luz en la banda verde) y 0,014 respectivamente para la variedad Senumisa 20, y 0,027 y 0,008 para la variedad Lazarroz. La banda azul para la variedad Lazarroz tuvo valores mínimos de reflectancia de 0,006 (Cuadro 2 y 3). La variación de los datos fue similar

para las tres bandas con coeficientes de variación máximos superiores al 20% y mínimos inferiores al 10% para la banda verde, y al 15% para las bandas azul y roja.

Cuadro 2. Valores promedio, desviación estándar y coeficiente de variación de las bandas e Índices de vegetación seleccionados con respecto a los grados día acumulados para la variedad Senumisa 20.

Banda o Índice de vegetación, desviación estándar (DE) y coeficiente de variación (cv)	Índice de Área Foliar								
	0,43	1,62	2,26	2,80	4,37	5,80	7,22	9,87	10,52
	Suma térmica (°C) / Días después de Emergencia								
	281/19	406/28	502/35	582/41	776/55	899/64	992/70	1066/76	1163/83
Verde	0,100	0,080	0,070	0,054	0,044	0,052	0,062	0,036	0,039
DE	0,018	0,011	0,005	0,010	0,003	0,007	0,012	0,010	0,007
cv (%)	17,66	13,85	7,50	19,02	7,64	13,49	19,43	27,38	18,29
Rojo	0,038	0,033	0,024	0,021	0,015	0,021	0,017	0,014	0,016
DE	0,007	0,008	0,004	0,005	0,002	0,002	0,003	0,003	0,003
cv (%)	17,90	24,52	15,37	26,02	14,60	13,97	18,42	26,32	2,01
WDRVI	0,104	0,110	0,138	0,134	0,156	0,139	0,169	0,161	0,159
DE	0,013	0,025	0,010	0,020	0,009	0,010	0,006	0,007	0,008
cv (%)	12,17	23,17	7,16	14,85	5,96	7,17	3,29	4,45	5,27
RVI	11,684	13,670	18,890	18,919	27,089	19,074	38,794	30,349	29,238
DE	1,774	5,540	3,135	6,037	5,783	3,410	7,245	5,181	5,581
cv (%)	15,18	40,53	16,60	31,91	21,35	17,88	18,68	17,07	19,09
NDRE	0,155	0,191	0,212	0,249	0,281	0,282	0,329	0,384	0,387
DE	0,017	0,018	0,007	0,014	0,006	0,007	0,004	0,005	0,006
cv (%)	10,72	10,80	7,49	13,20	7,02	11,23	10,40	9,64	7,84
TVI	1,157	1,162	1,182	1,179	1,194	1,182	1,203	1,198	1,196
DE	0,018	0,015	0,008	0,005	0,009	0,003	0,004	0,005	0,003
cv (%)	0,79	1,57	0,59	1,20	0,54	0,59	0,32	0,42	0,49

Los valores máximos de los índices de vegetación WDRVI, RVI, NDRE y TVI fueron de 0,169, 39,794, 0,387 y 1,203 respectivamente para Senumisa 20 y 0,182, 68,926, 0,452 y 1,212 para Lazarroz (Cuadro 2 y 3). Para ambas variedades, el índice con menor variación de los datos fue el TVI con coeficientes de variación menores al 2%, seguido por el NDRE y el WDRVI respectivamente, reduciendo considerablemente la variabilidad a partir de los 700°C aproximadamente para ambas

variedades con coeficientes de variación inferiores al 10%. El RVI fue el índice con mayor variabilidad con coeficientes de variación de entre 10% y 40%, y 32% para las variedades Senumisa 20 y Lazarroz respectivamente.

Cuadro 3. Valores promedio, desviación estándar y coeficiente de variación de las bandas e Índices de vegetación seleccionados con respecto a los grados día acumulados para la variedad Lazarroz.

Banda o Índice de vegetación, desviación estándar (DE) y coeficiente de variación (cv)	Índice de Área Foliar									
	0,98	1,51	2,86	4,32	6,71	9,33	11,00	13,88	15,54	17,77
	Suma térmica (°C) / Días después de Emergencia									
	329/ 17	451/ 26	545/ 32	716/ 45	823/ 53	901/ 59	979/ 65	1084/ 73	1177/ 80	1284/ 88
Azul	0,015	0,013	0,014	0,014	0,012	0,010	0,014	0,009	0,009	0,006
DE	0,002	0,003	0,003	0,003	0,001	0,002	0,002	0,002	0,001	0,002
cv (%)	15,46	25,15	18,53	19,20	12,12	18,99	13,46	21,20	13,18	26,21
Verde	0,054	0,042	0,060	0,039	0,036	0,036	0,039	0,028	0,026	0,027
DE	0,013	0,009	0,011	0,007	0,003	0,007	0,007	0,004	0,002	0,007
cv (%)	23,35	21,02	18,15	17,94	8,63	18,86	16,76	12,82	9,35	26,78
Rojo	0,024	0,019	0,020	0,016	0,015	0,012	0,017	0,010	0,010	0,008
DE	0,004	0,004	0,004	0,003	0,002	0,002	0,003	0,002	0,001	0,002
cv (%)	17,17	22,36	23,55	19,85	14,22	17,77	17,90	16,88	14,34	31,15
WDRVI	0,087	0,118	0,157	0,150	0,156	0,167	0,159	0,172	0,170	0,182
DE	0,025	0,022	0,012	0,007	0,013	0,004	0,005	0,007	0,004	0,002
cv (%)	28,51	18,19	7,62	4,75	8,40	2,18	3,26	3,88	2,59	2,51
RVI	10,052	14,722	28,678	23,558	28,422	36,237	28,447	43,009	40,465	68,926
DE	2,307	4,741	7,815	3,679	8,548	3,834	3,829	8,996	6,744	16,219
cv (%)	22,95	32,20	27,25	15,62	30,08	10,58	13,46	20,92	16,67	23,53
NDRE	0,175	0,251	0,299	0,346	0,371	0,375	0,407	0,434	0,452	0,449
DE	0,019	0,030	0,042	0,021	0,026	0,026	0,026	0,026	0,016	0,034
cv (%)	11,13	12,12	14,02	6,05	7,14	6,81	6,44	6,02	3,63	7,63
TVI	1,145	1,168	1,195	1,190	1,194	1,202	1,196	1,205	1,204	1,212
DE	0,018	0,015	0,008	0,005	0,009	0,003	0,004	0,005	0,003	0,003
cv (%)	1,58	1,31	0,70	0,42	0,77	0,21	0,30	0,38	0,25	0,26

Estos valores de referencia ayudarán al productor o técnico agrícola como una guía para un monitoreo rápido y preciso del estado general del cultivo, tanto para seleccionar un índice o banda espectral como para comparar sus datos con los de esta investigación, una vez identificadas las zonas problemáticas (cuyos valores serán inferiores a los reportados) permitirá tomar una decisión más precisa y no general sobre las medidas de manejo a tomar dependiendo de la problemática. Las medidas de variación flexibilizan la toma de decisiones, dando un margen a los valores obtenidos en los que pueden encontrarse antes de considerar realizar un análisis más profundo de una zona en específico y una posterior acción de manejo, ahorrando tiempo y recursos.

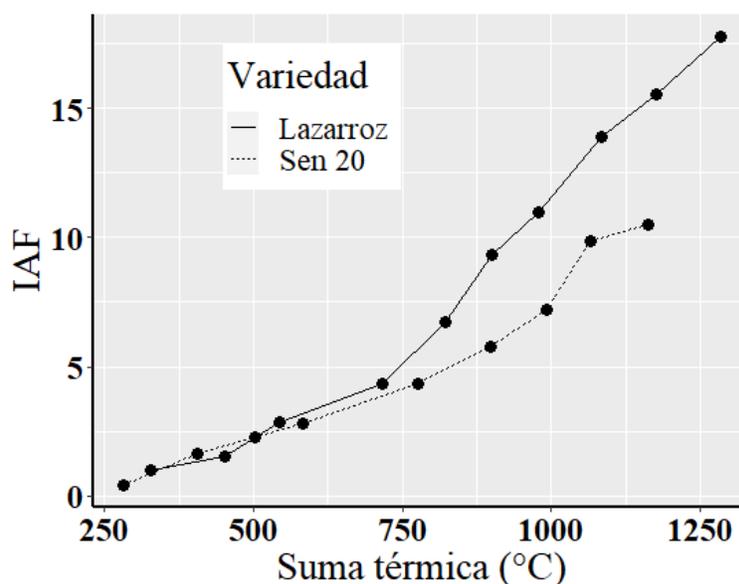


Figura 8. IAF promedio según la suma térmica para cada variedad desde los 15 días después de emergencia hasta la etapa de hoja bandera.

El IAF fue siempre creciente con respecto a la suma térmica para ambas variedades. Para la variedad Lazarroz llegó a un máximo de 17,77 y para la variedad Senumisa 20 a 10,52. A partir de los 750 °C acumulados aumento la tasa a la que el IAF crecía para la variedad Lazarroz y a los 1000°C para la variedad Senumisa 20, hubo un pequeño aumento (Figura 6).

Los modelos de regresión contruidos para cada variedad (Figura 7 y 8) consisten en la estimación de la variable de predicción IAF con respecto al índice NDRE, el cuál fue el único índice de vegetación con un R^2 superior a 0,7.

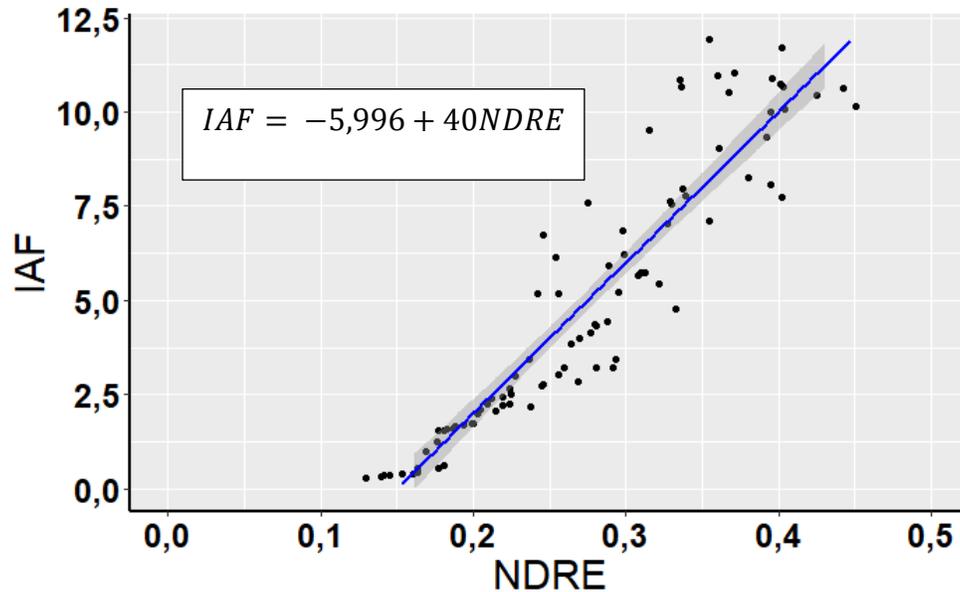


Figura 9. Modelo de regresión para predecir el IAF con respecto al NDRE para la variedad Senumisa 20, $n= 90$, $R^2= 0,86$.

El coeficiente del índice NDRE (la pendiente) del modelo es mayor para la variedad Lazarroz (Figura 8), que para el modelo de la variedad Senumisa 20 (Figura 7), esto quiere decir que por cada unidad que aumente el NDRE el IAF estimado será mayor para la variedad Lazarroz con respecto a la variedad Senumisa para un mismo valor del índice espectral. En concreto aumentará en 4 unidades el valor del IAF por cada aumento de 0,1 en el NDRE para la variedad Senumisa 20, y 5,81 para la variedad Lazarroz.

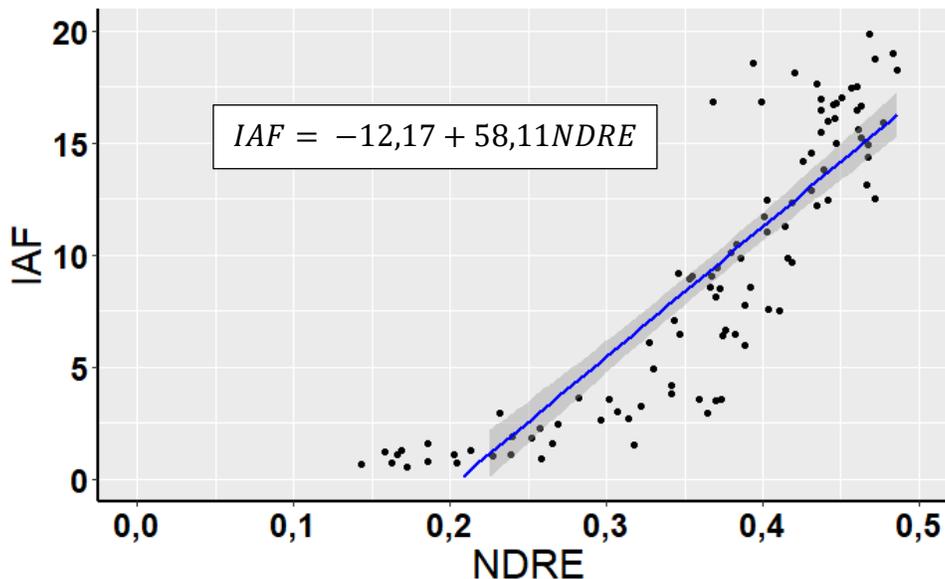


Figura 10. Modelo de regresión para predecir el IAF con respecto al NDRE para la variedad Lazarroz, $n= 99$, $R^2 = 0,77$.

El rendimiento del grano de la variedad Senumisa 20 en granza, limpio y seco (13% de humedad) fue de $7995,33 \pm 532,48 \text{ Kg ha}^{-1}$, $375,27 \pm 22,88$ panículas por metro cuadrado y $29,42 \pm 0,28$ g para el peso de mil granos. Para la variedad Lazarroz el rendimiento en las mismas condiciones fue de $10625,73 \pm 700,20 \text{ Kg ha}^{-1}$, $433,4 \pm 21,39$ panículas por metro cuadrado y $28,95 \pm 1,16$ g para el peso de mil granos.

La utilidad de estos modelos de regresión es estimar valores de IAF de forma sencilla ahorrando tiempo y dinero con varios propósitos, como la investigación o para tomar decisiones de manejo de forma más precisa. Es posible realizar un mejor uso del agua al conocer la cantidad de biomasa (parámetro que está muy relacionado al IAF) que se encuentra en un lote para distintos propósitos como la aplicación de insumos o riego. La comprobación de la precisión de los modelos es necesaria antes de decidir utilizarlos.

El NDRE también fue el único índice que tuvo una buena correlación (superior a 0,6) con respecto al rendimiento para ambas variedades y el único con buena correlación para la variedad Senumisa 20 (Cuadro 4). Para la variedad Lazarroz hubo

buenas correlaciones para todas las bandas espectrales utilizadas menos la del Infrarrojo cercano y para los índices RGBVI y NDRE (Cuadro 4).

Cuadro 4. Coeficientes de correlación de Pearson (r) de las bandas espectrales y los índices de vegetación contra el rendimiento en Kg ha⁻¹ según la variedad de arroz.

Variedad	Bandas espectrales					Índices de vegetación					
	Azul	Verde	Roja	Borde Rojo	Infrarrojo cercano	WDRVI	RDVI	RVI	RGBVI	NDRE	TVI
Senumisa	0,14	0,03	0,11	-0,12	0,20	0,03	0,12	0,012	-0,23	0,71	0,03
Lazarroz	-0,70	-0,80	-0,64	-0,76	-0,40	0,30	-0,35	0,34	-0,86	0,81	0,31

Obtener buenas correlaciones para el NDRE con respecto al rendimiento de ambas variedades da un mayor respaldo a la decisión de optar por utilizar este índice para el monitoreo del cultivo y da una base para futuras investigaciones relacionadas con la predicción del rendimiento para estas variedades.

6. Discusión

6.1. IAF y reflectancia

La reflectancia de todas las bandas espectrales analizadas disminuyó conforme aumentó el IAF excepto por la del infrarrojo cercano, la cual tiene una correlación positiva con respecto al IAF (Cuadro 1). Esto es consistente con la teoría ya que conforme aumenta el IAF también aumenta la intercepción de luz PAR (Luz Fotosintéticamente Activa por sus siglas en inglés), el porcentaje de luz absorbida y por lo tanto una disminución del porcentaje de luz reflejada, excepto en la etapa de senescencia (Peng 2000). El contraste entre la región visible con la banda del Infrarrojo cercano es típico de la firma espectral de la vegetación y hace posible el uso de índices de vegetación para teledetección (Zhang et al., 2019).

La correlación entre el IAF y la reflectancia de las bandas espectrales correspondientes al espectro visible fue negativa, la reflectancia para la variedad Lazarroz fue por lo general menor con respecto a la variedad Senumisa 20 (Cuadro 2 y 3), debido probablemente a diferencias en el porte de la planta que generan diferencias en la absorción de luz, principalmente el ángulo de inserción de la hoja.

Dingkuhn et al., (1990), encontró que las plantas de arroz con una arquitectura del dosel con hojas largas y con un ángulo de apertura mayor siempre se saturan a plena luz del día independientemente del IAF, esto no sucede cuando la arquitectura del cultivo corresponde a hojas cortas y erectas. La arquitectura erecta del dosel de la variedad Lazarroz podría explicar tanto la menor reflectancia debido a una mayor absorción ya que el sistema fotosintético no se satura, y a una mayor intercepción de luz por valores altos de IAF con respecto a la Senumisa 20, podría deberse también a una mayor transmisión de la luz. Es por esto que el programa de mejoramiento se dirige a la selección de variedades de forma que se obtenga una arquitectura del cultivo más erecta.

6.2. Índices de vegetación

La mayoría de los índices de vegetación utilizados en la investigación utilizan las bandas roja e infrarroja cercana, excepto por el RGBVI y el NDRE, este último

utiliza el borde rojo e infrarrojo cercano y fue el índice con mejor correlación con respecto al rendimiento y el IAF. El área de la firma espectral comprendida entre las bandas del rojo y el infrarrojo en donde se da un cambio creciente de la reflectancia es conocida como borde rojo y de acuerdo con Kang et al., (2021) es la más sensible a cambios en la sanidad de la planta.

Los índices que incluyen la banda borde rojo presentan una mejoría con respecto al método tradicional (utilizando índices de vegetación con las bandas Azul, Verde, Roja e Infrarroja) de forma notable cuando las condiciones del cultivo son de un follaje denso en etapas avanzadas de desarrollo, ya que la absorbancia de luz roja es muy alta y se dice que el índice de vegetación se satura (no presenta variaciones), sin embargo, el uso de la banda borde rojo reduce este efecto ya que por definición la reflectancia en la banda del borde roja siempre es mayor a la de la banda roja aunque menor que la banda Infrarroja cercana lo que permite que también pueda ser utilizada en índices de vegetación (Zhang et al., 2019).

Al utilizar el método tradicional es posible obtener buenas correlaciones, sin embargo, el uso de la banda del borde rojo representa una mejora en la precisión de los modelos y en los valores de correlación (Cuadro 1). Cui & Kerekes (2018) también obtuvieron mejorías en sus modelos para estimar el IAF con imágenes espectrales del Landsat 8 al utilizar distintas bandas en el espectro del borde rojo en comparación al método tradicional, atribuían mejoras cuando se utilizan imágenes del Sentinel-2 a que la banda del borde rojo era más estrecha, sin embargo, en la presente investigación todas las bandas tienen el mismo ancho por lo que esto no entra en consideración.

Zhang et al., (2019) también obtuvieron mejoras significativas en sus modelos para predecir el rendimiento al utilizar índices que incluyen la banda del borde rojo en comparación al método tradicional, lo mismo sucedió prediciendo y estimando el IAF, y prediciendo el contenido de materia seca y la acumulación de nitrógeno total y foliar.

Los índices de vegetación por lo general se utilizan en agricultura para estimar parámetros del cultivo como los mencionados anteriormente y no se encontró bibliografía del uso de valores de referencia, como en el caso de esta investigación para el cultivo de arroz. Este acercamiento es similar a métodos tradicionales de referencia

para el manejo del cultivo como el de las curvas de absorción de nutrientes (Molina, 2012). Al igual que en estas curvas, aunque se pretende encontrar los valores con los cuales se alcance un buen rendimiento, no pretende establecerlos como los valores óptimos sino servir como una guía para el técnico agrícola. Estos valores (los de los índices y bandas con correlaciones superiores a 0,7) a diferencia de los de una curva de absorción presentan la facilidad de ser medidos utilizando sensores espectrales que pueden colocarse en plataformas como drones, los cuales cubren grandes extensiones, creando mapas y priorizando el manejo a las zonas que lo requieran, al estar sustentados en análisis estadísticos con respecto al IAF y el rendimiento cobran mayor validez para el monitoreo del crecimiento del cultivo para obtener buenos rendimientos. El NDRE por todo lo mencionado en este apartado y los resultados obtenidos es el índice de vegetación más apropiado para el monitoreo del cultivo de arroz debido a su alta correlación con el IAF y el rendimiento, junto con una menor variación dentro de la muestra con respecto a los otros índices de vegetación.

6.3. Índice de Área foliar

Las variedades de arroz tienen una arquitectura y una tasa fotosintética potencial de la hoja definida, por lo que solo queda encontrar un IAF óptimo y alcanzarlo para aumentar el rendimiento. El IAF óptimo es aquel en el cual la tasa neta de fotosíntesis del dosel y la de crecimiento del cultivo alcanzan valores máximos, y si se aumenta, estas tasas disminuyen (Dingkuhn et al., 1990). Este IAF óptimo depende de la etapa de la fenología y la cantidad de luz PAR, para una variedad de hojas erectas es mayor que para una variedad con hojas más horizontales (Dingkuhn et al., 1990).

De acuerdo con Peng (2000), el IAF máximo se alcanza en la etapa fenológica conocida como inicio de la emergencia de panícula, y se han reportado valores de hasta 20 aunque se sospecha altos efectos de borde. Sin embargo, Akita (1989) observó valores máximos de 17, aunque el promedio de las publicaciones en ese momento era de entre 8 y 12 (Peng 2000). La variedad Senumisa 20 tuvo un IAF máximo dentro del rango de valores promedio mencionado y la Lazarroz alcanzó valores muy superiores, sin llegar al máximo reportado. Esta última es una variedad de hojas especialmente

erectas en comparación con la Senumisa 20, por lo que el IAF óptimo debería de ser superior, esto podría explicar también el mayor rendimiento obtenido ya que hay una correlación entre el ángulo de inserción de la hoja, el IAF y el rendimiento (Sinclair & Sheehy, 1999). El uso de una alta densidad de siembra probablemente afectó de manera positiva el IAF, el número de tallos y panículas por unidad de suelo, y en última instancia el rendimiento, aunque debido a las limitaciones de la investigación no es posible saber si el IAF durante el desarrollo fue inferior o superior al óptimo.

El IAF como se ha mencionado, tiene un papel coprotagonico en el rendimiento del arroz, por lo que en el pasado se utilizaban muestreos de este índice y de biomasa para predecirlo mediante modelos de regresión (Zhang et al., 2019). Zhang et al., (2019), obtuvieron coeficientes de determinación entre valores de IAF en distintas etapas de crecimiento y el rendimiento de hasta 0,82. Por esto, es posible utilizar el IAF como una herramienta de monitoreo del crecimiento con el propósito de obtener buenos rendimientos, especialmente si se tienen valores de referencia como se han generado en la presente investigación.

El IAF se mide de forma destructiva, esta labor consume mucho tiempo y esfuerzo sobre todo en cultivos donde el IAF alcanza valores muy altos como es el caso del arroz. El uso de sensores de mano para estimar el IAF puede resultar una herramienta muy útil que facilita y agiliza la labor cuando es necesario obtener una gran cantidad de datos y los recursos son limitados, como fue el caso de esta investigación, al comparar los valores promedios semanales obtenidos con el ceptómetro contra los valores reales medidos de forma tradicional se obtuvieron coeficientes de determinación cercanos a 1 para ambas variedades. Estos resultados se pueden encontrar en los Anexos 4 y 5. Pokovai & Fodor (2019), obtuvieron coeficientes de determinación de 0,86 entre los valores de IAF estimados con el ceptómetro y los de muestras destructivas para el cultivo de trigo, el cual tiene una arquitectura similar a la del arroz. Estos valores se obtuvieron al utilizar el valor del parámetro de distribución de las hojas del ceptómetro constante (el estudio se llevó a cabo durante 3 semanas antes de la emergencia de panícula). En la presente investigación el parámetro de distribución de las hojas fue estimado semanalmente

mediante prueba y error, lo que podría explicar valores mayores para los coeficientes de determinación.

. Los modelos de regresión elaborados podrían ayudar a facilitar la labor, sobre todo si se trata de conocer el IAF con fines productivos, sin embargo, deben ser probados para verificar su precisión y exactitud antes de ser utilizados.

El estudio de los coeficientes de determinación para las mediciones y estimaciones del IAF, se realizó entre el IAF real y el IAF promedio de las diez mediciones semanales con el ceptómetro, y no contra un IAF estimado con el ceptómetro en el área de la muestra destructiva. Los modelos de regresión elaborados podrían ayudar a facilitar la labor, sin embargo, deben ser probados para verificar su precisión como su exactitud antes de ser utilizados.

6.4. Rendimiento

Peng et al. (1999), mencionan que el rendimiento potencial del cultivo de arroz en el trópico es de 10 t ha^{-1} (valor que aún se utiliza por instituciones como la FAO). Las dos variedades utilizadas superaron el promedio nacional para el ciclo pasado, por lo que se considera que la parcela y los valores espectrales generados pueden usarse como referencia para el monitoreo del crecimiento, apuntando a aumentar el rendimiento. La variedad Lazarroz alcanzó el potencial para el trópico, la variedad Senumisa 20 no lo alcanzó, no obstante, fue un 78% mayor que el rendimiento promedio nacional. El manejo del cultivo fue similar al utilizado por los productores excepto por la densidad de siembra, la cual fue 35 más alta que la utilizada tradicionalmente (115 kg ha^{-1}). Arias-Badilla et al., (2020), obtuvieron rendimientos similares ($7,7\text{ t ha}^{-1}$) con la variedad Lazarroz utilizando esta misma densidad. Otro aspecto que pudo afectar de forma positiva el rendimiento fue la orientación de las hileras las cuales estaban en sentido este-oeste para aumentar la disponibilidad de luz PAR (luz fotosintéticamente activa, que comprenden la luz azul y roja) sobre todo en horas de la mañana y la tarde.

El rendimiento según Peng (2000), está determinado por dos componentes principales; el índice de cosecha, el cuál para cultivos de granos es la relación entre el

peso de los granos y la materia seca del tallo, y la biomasa. El índice de cosecha entre cultivares de arroz actualmente varía de 35 a 62% para los más productivos (generalmente híbridos) (Amanullah & Inamullah, 2016). El mejoramiento de cultivos de granos para aumentar el índice de cosecha es difícil cuando se han alcanzado niveles tan altos, por lo que aumentar la cantidad de biomasa es más sencillo, esto implica a su vez aumentar la captura de carbono mediante un aumento de la tasa neta de fotosíntesis del dosel, que está en función del índice de área foliar, la arquitectura del dosel y la tasa fotosintética neta de la hoja (Dingkuhn et al., 1990).

El fundamento antes mencionado en el que a mayor biomasa mayor es el rendimiento, se basa en la relación entre reflectancia y rendimiento. El rendimiento al igual que la reflectancia dependen de la biomasa. También por esto se utiliza el IAF para predecir el rendimiento (Zhang et al., 2019), ya que el IAF está correlacionado con la cantidad de biomasa; no es de extrañar que el mismo índice con una alta correlación con respecto al IAF también tenga una alta correlación con el rendimiento como es el caso de NDRE (Cuadro 4).

Zhou et al., (2017) obtuvieron una correlación de 0,89 entre el IAF y el NDRE, y hasta 0,87 entre el rendimiento y este mismo índice. Duan et al., (2019) obtuvieron correlaciones de 0,9 entre el IAF y el NDRE, y 0,73 entre el rendimiento y el NDRE en el cultivo de trigo. Estos valores son similares a los obtenidos. Además, el valor del coeficiente de correlación entre el IAF y el NDRE es siempre mayor que el del NDRE con el rendimiento. Debido probablemente a que la reflectancia es producto directo de la cantidad de biomasa, sin embargo, no pasa lo mismo con el rendimiento, sino que este es producto de la biomasa, y puede verse afectado por otros factores, es decir, no siempre a mayor biomasa mayor es el rendimiento. Como se mencionó anteriormente, si el IAF es mayor al valor óptimo se producirá sombreo y la tasa fotosintética del dosel y la de crecimiento no alcanzarán su potencial, también pueden darse problemas de otra índole que afecten el rendimiento como plagas y enfermedades que afecten las etapas avanzadas de desarrollo.

7. Conclusiones y Recomendaciones

7.1. Conforme se desarrolla el cultivo, el IAF y la absorción de luz PAR aumentan y la reflectancia disminuye, a valores altos de IAF la absorción de esta luz se maximiza y los índices que utilizan bandas espectrales tradicionales tienden a saturarse; esto no sucede con los índices que usan la banda del borde rojo (NDRE).

7.2. Los valores de referencia reportados tienen validez estadística para su uso en el monitoreo del crecimiento del cultivo, sobre todo los del NDRE, debido a los altos valores de los coeficientes de correlación y determinación alcanzados con respecto al IAF y el rendimiento.

7.3. La variedad con porte erecto alcanzó mayores valores de IAF y por lo tanto mayores rendimientos, debido a que las hojas no se saturan, y a una mayor intercepción de luz que resulta en un incremento de la tasa fotosintética del dosel.

7.4. El uso de variedades con un porte erecto como la Lazarroz en combinación con mayores densidades de siembra podrían ayudar a aumentar los rendimientos a nivel nacional. Esto podría complementarse con un aumento en los niveles de nutrientes en la fertilización.

7.5. Se recomienda para futuras investigaciones encontrar las mejores densidades de siembra para las variedades más utilizadas en combinación con distintas dosis de fertilización, con las cuales se alcance el IAF óptimo a la vez de que se registren los valores de reflectancia de distintas bandas espectrales con la finalidad de mediante técnicas válidas de teledetección monitorear el IAF, utilizando el IAF óptimo según la suma térmica como valores de referencia.

8. Anexos

Anexo 1. Valores óptimos de contenido foliar de nutrientes en el cultivo de arroz (Molina, 2012).

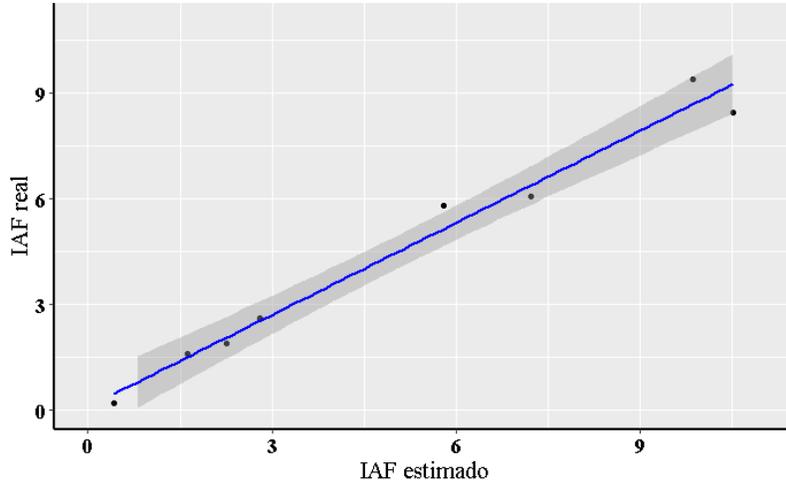
%						mg.kg ⁻¹				
N	P	Ca	Mg	K	S	Fe	Cu	Zn	Mn	B
3,03	0,23	0,23	0,13	2,09	0,14	118	14	32	937	12,2

Anexo 2. Resultados de los análisis químicos foliares para las variedades Senumisa 20 y Lazarroz, de las muestras tomadas en la etapa de hoja bandera.

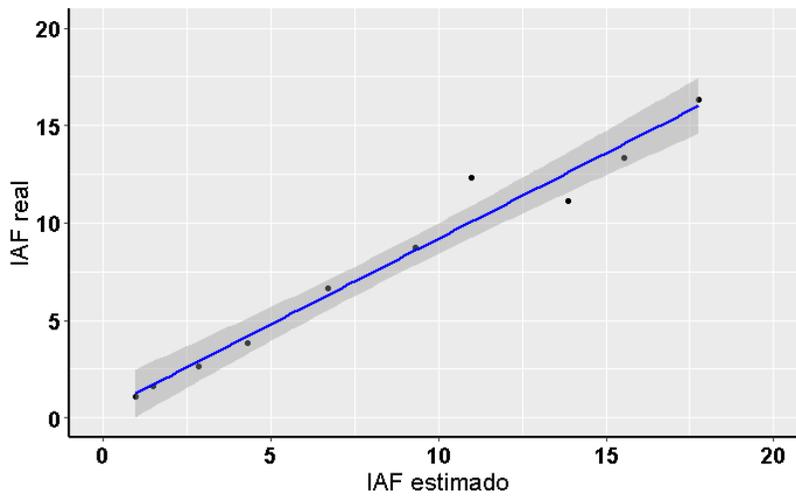
Variedad	%						mg.kg ⁻¹				
	N	P	Ca	Mg	K	S	Fe	Cu	Zn	Mn	B
Senumisa 20	2,76	0,11	0,32	0,10	1,56	0,17	83	16	17	576	3
Lazarroz	2,66	0,13	0,33	0,10	1,71	0,15	89	17	17	815	10

Anexo 3. Resultados del análisis químico completo de suelos para las variedades Senumisa 20 y Lazarroz.

Variedad	pH	cmol (+)/L					%	mg/L				
	H ₂ O	Acidez	Ca	Mg	K	CICE	SA	P	Zn	Cu	Fe	Mn
Senumisa 20	5,5	0,5	4	1	0,2	5		10	3	1	10	5
Lazarroz	6,3	0,15	10,59	5,01	0,46	16,21	0,9	2	1,3	13	166	12
Lazarroz	6,0	0,15	9,21	4,19	0,15	13,70	1	6	1,6	10	126	5



Anexo 4. Valores reales de IAF contra el promedio de los valores estimados con el ceptómetro durante 8 semanas para la variedad Senumisa 20, $R^2= 0,97$.



Anexo 5. Valores reales de IAF contra el promedio de los valores estimados con el ceptómetro durante 10 semanas para la variedad Lazarroz, $R^2= 0,98$.

10. Bibliografía

- Akita S. 1989. Improving yield potential in tropical rice. In: Progress in irrigated rice research. Manila (Philippines). *International Rice Research Institute*. p 41-73.
- Amanullah, & Inamullah. (2016). Dry Matter Partitioning and Harvest Index Differ in Rice Genotypes with Variable Rates of Phosphorus and Zinc Nutrition. *Rice Science*, 23(2), 78–87. <https://doi.org/10.1016/j.rsci.2015.09.006>
- Arias-Badilla, J. G., Esquivel-Segura, E. A., & Campos-Rodríguez, R. (2020). Evaluación de la densidad de siembra y nivel de fertilización en arroz, para las variedades Palmar-18, Lazarroz FL y NayuribeB FL, en Parrita (Pacífico Central), Costa Rica. *Revista Tecnología en Marcha*, 33(3), 13-24. <https://doi.org/10.18845/tm.v33i3.4363>
- Bennett, R., Oosterom, P. van, Lemmen, C., & Koeva, M. (2020). Remote sensing for land administration. *Remote Sensing*, 12(15), 1–8. <https://doi.org/10.3390/RS12152497>
- Chen, J. M. (2017). Remote sensing of leaf area index and clumping index. In *Comprehensive Remote Sensing* (Vols. 1–9). Elsevier. <https://doi.org/10.1016/B978-0-12-409548-9.10540-8>
- CONARROZ. (2020). *Informe anual estadístico 2019/2020*.
- Cui, Z., & Kerekes, J. P. (2018). Potential of red edge spectral bands in future landsat satellites on agroecosystem canopy green leaf area index retrieval. *Remote Sensing*, 10(9). <https://doi.org/10.3390/rs10091458>
- De Araujo Barbosa, C. C., Atkinson, P. M., & Dearing, J. A. (2015). Remote sensing of ecosystem services: A systematic review. *Ecological Indicators*, 52, 430–443. <https://doi.org/10.1016/j.ecolind.2015.01.007>
- DeFries, R. (2013). Remote Sensing and Image Processing. *Encyclopedia of Biodiversity: Second Edition*, 5, 389–399. <https://doi.org/10.1016/B978-0-12-384719-5.00383-X>

- del Río-Mena, T., Willemen, L., Vrieling, A., & Nelson, A. (2020). Understanding intra-annual dynamics of ecosystem services using satellite image time series. *Remote Sensing*, *12*(4). <https://doi.org/10.3390/rs12040710>
- Dingkuhn, M., Schnier, H. F., De Datta, S. K., Dörffling, K., Javellana, C., & Pamplona, R. (1990). Nitrogen Fertilization of Direct-Seeded Flooded vs. Transplanted Rice: II. Interactions among Canopy Properties. *Crop Science*, *30*(6), 1284–1292. <https://doi.org/10.2135/cropsci1990.0011183x003000060025x>
- dos Santos, C. L., Roberts, T. L., & Purcell, L. C. (2020). Canopy greenness as a midseason nitrogen management tool in corn production. *Agronomy Journal*, 1–23. <https://doi.org/10.1002/agj2.20443>
- Duan, B., Fang, S., Zhu, R., Wu, X., Wang, S., Gong, Y., & Peng, Y. (2019). Remote estimation of rice yield with unmanned aerial vehicle (uav) data and spectral mixture analysis. *Frontiers in Plant Science*, *10*. <https://doi.org/10.3389/fpls.2019.00204>
- Fang, H., Baret, F., Plummer, S., & Schaepman-Strub, G. (2019). An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications. *Reviews of Geophysics*, *57*(3), 739–799. <https://doi.org/10.1029/2018RG000608>
- Foster, A., Atwell, S., & Dunn, D. (2017). Sensor-based Nitrogen Fertilization for Midseason Rice Production in Southeast Missouri. *Crop, Forage & Turfgrass Management*, *3*(1), cftm2017.01.0005. <https://doi.org/10.2134/cftm2017.01.0005>
- Geng, J., Yuan, G., Chen, J. M., Lyu, C., Tu, L., Fan, W., Tian, Q., Wu, Z., Tao, T., Yu, M., Zhu, Y., Huang, J., Xu, K., Li, J., & Wang, S. (2021). Error analysis of lai measurements with lai-2000 due to discrete view angular range angles for continuous canopies. *Remote Sensing*, *13*(7), 1–19. <https://doi.org/10.3390/rs13071405>
- González-Betancourt, M., & Mayorga-Ruiz, Z. L. (2018). Normalized difference vegetation index for rice management in el Espinal, Colombia. *DYNA (Colombia)*, *85*(205), 47–56. <https://doi.org/10.15446/dyna.v85n205.69516>

- Guan, S., Fukami, K., Matsunaka, H., Okami, M., Tanaka, R., Nakano, H., Sakai, T., Nakano, K., Ohdan, H., & Takahashi, K. (2019). Assessing correlation of high-resolution NDVI with fertilizer application level and yield of rice and wheat crops using small UAVs. *Remote Sensing*, *11*(2), 2–19. <https://doi.org/10.3390/rs11020112>
- Guha, A. (2020). Mineral exploration using hyperspectral data. In *Hyperspectral Remote Sensing*. LTD. <https://doi.org/10.1016/b978-0-08-102894-0.00012-7>
- Horning, N. (2008). Encyclopedia of Ecology. *Encyclopedia of Ecology, 2000*, 2986–2994. <http://www.sciencedirect.com/science/article/pii/B9780080454054002378>
- Hu, C., Sapkota, B. B., Thomasson, J. A., & Bagavathiannan, M. V. (2021). Influence of image quality and light consistency on the performance of convolutional neural networks for weed mapping. *Remote Sensing*, *13*(11). <https://doi.org/10.3390/rs13112140>
- Huete, A. R. (2004). Remote Sensing for Environmental Monitoring. In *Environmental Monitoring and Characterization*. Elsevier, Inc. <https://doi.org/10.1016/B978-0-12-064477-3.50013-8>
- Kang, Y., Meng, Q., Liu, M., Zou, Y., & Wang, X. (2021). Crop classification based on red edge features analysis of gf-6 wfv data. *Sensors*, *21*(13). <https://doi.org/10.3390/s21134328>
- Khanal, S., Kushal, K. C., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote sensing in agriculture—accomplishments, limitations, and opportunities. *Remote Sensing*, *12*(22), 1–29. <https://doi.org/10.3390/rs12223783>
- Lee, K. H., & Wong, M. S. (2018). Vertical Profiling of Aerosol Optical Properties From LIDAR Remote Sensing, Surface Visibility, and Columnar Extinction Measurements. In *Remote Sensing of Aerosols, Clouds, and Precipitation*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-810437-8.00002-5>
- Leslie, R. V. (2017). Microwave sensors. In *Comprehensive Remote Sensing* (Vols. 1–9). Elsevier. <https://doi.org/10.1016/B978-0-12-409548-9.10328-8>

- Liang, S., & Wang, J. (2020a). A systematic view of remote sensing. In S. Liang & J. Wang (Eds.), *Advanced Remote Sensing*. <https://doi.org/10.1016/b978-0-12-815826-5.00001-5>
- Liang, S., & Wang, J. (2020b). Advanced Remote Sensing. In *Advanced Remote Sensing* (pp. 405–445). Elsevier. <https://doi.org/10.1016/B978-0-12-815826-5.00010-6>
- Machwitz, M., Pieruschka, R., Berger, K., Schlerf, M., Aasen, H., Fahrner, S., Jiménez-Berni, J., Baret, F., & Rascher, U. (2021). Bridging the Gap Between Remote Sensing and Plant Phenotyping—Challenges and Opportunities for the Next Generation of Sustainable Agriculture. *Frontiers in Plant Science*, *12*(October), 1–7. <https://doi.org/10.3389/fpls.2021.749374>
- Mastelic, T., Lorincz, J., Ivandic, I., & Boban, M. (2020). Aerial imagery based on commercial flights as remote sensing platform. *Sensors (Switzerland)*, *20*(6), 1–22. <https://doi.org/10.3390/s20061658>
- Mohd Noor, N., Abdullah, A., & Hashim, M. (2018). Remote sensing UAV/drones and its applications for urban areas: A review. *IOP Conference Series: Earth and Environmental Science*, *169*(1). <https://doi.org/10.1088/1755-1315/169/1/012003>
- Molina, E. (2012). Fertilización con N, P, K y S, y curvas de absorción de nutrientes en arroz var. CFX18 en Guanacaste. *Agronomía Costarricense*, *36*(1), 39–51. <https://www.scielo.sa.cr/pdf/ac/v36n1/a03v36n1.pdf>
- Molina, F., Terra, J., & Roel, A. (2019). Evolución de algunas variables tecnológicas en el cultivo de arroz en Uruguay. *Instituto Nacional de Investigación Agropecuaria*, *250*, 1–3. <https://doi.org/http://doi.org.10.35676/INIA/ST.250>
- Muriado, J., Velez, J., Salvatierra, P., Scaramuzza, F., & Villaroel, D. (2007). Evaluación de la predicción de rendimiento realizada con “Calculadora de la dosis de nitrógeno basada en sensores” en el cultivo de trigo (*Triticum aestivum* L.). *Inta*.
- Nuarsa, I. W., Nishio, F., & Hongo, C. (2011). Spectral Characteristics and Mapping

of Rice Plants Using Multi-Temporal Landsat Data. *Journal of Agricultural Science*, 3(1), 54–67. <https://doi.org/10.5539/jas.v3n1p54>

Oliveira, D., Gico, S., Oliveira, P., Bezerra, J., Barbosa, J., da Silva, E., da Silva, A., dos Santos, Wellington, Acuña-Chinchilla, S., Barros, R., & Nascimento, D. (2020). Monitoring of degradation in the Caatinga biome in the semi-arid northeastern region, Brazil. *Revista Brasileira de Geografia Física*, 13(05), 2293–2303.

Olson, D., Chatterjee, A., & Franzen, D. W. (2019). Can we select sugarbeet harvesting dates using drone-based vegetation indices? *Agronomy Journal*, 111(5), 2619–2624. <https://doi.org/10.2134/agronj2019.03.0219>

Paliwal, A., & Jain, M. (2020). The Accuracy of Self-Reported Crop Yield Estimates and Their Ability to Train Remote Sensing Algorithms. *Frontiers in Sustainable Food Systems*, 4(March), 1–10. <https://doi.org/10.3389/fsufs.2020.00025>

Panek, E., & Gozdowski, D. (2020). Analysis of relationship between cereal yield and NDVI for selected regions of Central Europe based on MODIS satellite data. *Remote Sensing Applications: Society and Environment*, 17(August 2019), 100286. <https://doi.org/10.1016/j.rsase.2019.100286>

Patil, P., Biradar, P., U. Bhagawathi, A., & S. Hejjeagar, I. (2018). A Review on Leaf Area Index of Horticulture Crops and Its Importance. *International Journal of Current Microbiology and Applied Sciences*, 7(04), 505–513. <https://doi.org/10.20546/ijcmas.2018.704.059>

Peng, S., Cassman, K. G., Virmani, S. S., Sheehy, J., & Khush, G. S. (1999). Yield potential trends of tropical rice since the release of IR8 and the challenge of increasing rice yield potential. *Crop Science*, 39(6), 1552–1559. <https://doi.org/10.2135/cropsci1999.3961552x>

Peteinatos, G. G., Korsath, A., Berge, T. W., & Gerhards, R. (2016). Using optical sensors to identify water deprivation, nitrogen shortage, weed presence and fungal infection in wheat. *Agriculture (Switzerland)*, 6(2). <https://doi.org/10.3390/agriculture6020024>

- Pokovai, K., & Fodor, N. (2019). Adjusting ceptometer data to improve leaf area index measurements. *Agronomy*, 9(12), 1–13. <https://doi.org/10.3390/agronomy9120866>
- Power, A. G. (2010). Ecosystem services and agriculture: Tradeoffs and synergies. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 365(1554), 2959–2971. <https://doi.org/10.1098/rstb.2010.0143>
- Singh, L. A., Whittecar, W. R., DiPrinzio, M. D., Herman, J. D., Ferringer, M. P., & Reed, P. M. (2020). Low cost satellite constellations for nearly continuous global coverage. *Nature Communications*, 11(1), 1–7. <https://doi.org/10.1038/s41467-019-13865-0>
- Tilly, N., Aasen, H., & Bareth, G. (2015). Fusion of plant height and vegetation indices for the estimation of barley biomass. *Remote Sensing*, 7(9), 11449–11480. <https://doi.org/10.3390/rs70911449>
- Toth, C., & Józków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22–36. <https://doi.org/10.1016/j.isprsjprs.2015.10.004>
- Unninayar, S., & Olsen, L. M. (2015). Monitoring, Observations, and Remote Sensing – Global Dimensions☆. In *Reference Module in Earth Systems and Environmental Sciences* (#edition#, Issue September). Elsevier Inc. <https://doi.org/10.1016/b978-0-12-409548-9.09572-5>
- Velázquez, J., Rosales, A., Rodríguez, H., & Salas, R. (2015). Determinación de las etapas de inicio de macollamiento, inicio de primordio, floración y madurez en la planta de arroz, con el sistema S, V y R correlacionado con la sumatoria térmica. *Agronomía Costarricense*, 39(2), 121–129. <https://doi.org/10.15517/rac.v39i2.21781>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236(December 2018), 111402. <https://doi.org/10.1016/j.rse.2019.111402>

- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017, 1–17. <https://doi.org/10.1155/2017/1353691>
- Yin, N., Liu, R., Zeng, B., & Liu, N. (2019). A review: UAV-based Remote Sensing. *IOP Conference Series: Materials Science and Engineering*, 490(6). <https://doi.org/10.1088/1757-899X/490/6/062014>
- Zhang, K., Ge, X., Shen, P., Li, W., Liu, X., Cao, Q., Zhu, Y., Cao, W., & Tian, Y. (2019). Predicting rice grain yield based on dynamic changes in vegetation indexes during early to mid-growth stages. *Remote Sensing*, 11(4), 1–24. <https://doi.org/10.3390/rs11040387>
- Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., Cheng, T., Zhu, Y., Cao, W. X., & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246–255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>