

Universidad de Costa Rica
Sistema de Estudios de Posgrado

Universidad Nacional
Sistema de Estudios de Posgrado
Escuela de Ciencias Geográficas

Programa de Maestría Profesional en Sistemas de Información Geográfica y
Teledetección

**Predicción de altura de la planta y rendimiento del sorgo mediante datos
multiespectrales y fotogrametría de RPAS**

Trabajo final de investigación sometido a consideración de la Comisión del
Programa de Estudios de Posgrado en Geografía para optar al grado y título de
Maestría Profesional en Sistemas de Información Geográfica y Teledetección.

Kevin Carrillo Montoya

Ciudad Universitaria Rodrigo Facio, Montes de Oca

San José, Costa Rica, 2024

Dedicatoria

A quienes me inspiraron y ayudaron a llegar donde estoy, a mi familia mis verdaderos héroes.

Con amor, a mi padre, gracias por enseñarme a tener resiliencia ante los desafíos, un abrazo grande hasta donde estés.

Kevin

Agradecimientos

No imaginaría que después de dos años estaría en esta etapa, es increíble como pasa el tiempo de rápido. Debo agradecer primeramente a mi compañera de viaje en este proceso, **María**, sin usted todo hubiese sido el doble de difícil, gracias por allanar el camino, por ser esa persona incondicional y por todo el apoyo las veces que no estuve motivado, estaré en deuda toda mi vida.

A todo el personal del Centro de Innovación Enrique Jiménez Núñez del INTA, por toda su disposición para la ejecución de esta actividad; el personal de este lugar es sencillamente excepcional.

Al PhD. Roberto Camacho Montero, quién creyó en este proyecto desde un inicio y le brindó el soporte necesario, Roberto, no tengo palabras para describir mi agradecimiento durante todo este proceso y el venidero. Además, reconocer al PhD. Nevio Bonilla Morales, por todos sus aportes, colaboración y confianza depositada en mi persona para la ejecución de esta investigación, un fraterno agradecimiento.

Al profesor MSc. Jorge Claudio Vargas, quien ha sido un ejemplo para mi formación profesional durante mucho tiempo, ya que ha demostrado su excelencia académica con aportes científicos de gran magnitud, gracias Claudio por acompañarme en este camino, que la vida recompense de la manera que anhelas para usted y su familia.

A los profesores MSc. Melvin Lizano y Ramón Masís, gracias por su valiosa colaboración en la planificación y excelentes aportes durante la ejecución de este proyecto, estaré siempre agradecido por el tiempo brindado. Al Profesor M.Sc. Francisco Rodríguez, quien incentivó en cada semestre la culminación de este trabajo, su seguimiento fue valioso para poder llegar a este punto, gracias.

A mis compañeros y amigos PhD. William Sánchez, MSc. Jose Pablo Jiménez e Ing. Vidal Vega de la unidad pecuaria del INTA, además de la Ing. Valerie Salazar del Ministerio de Agricultura y Ganadería, gracias por toda la colaboración en campo, no tengo palabras para agradecer todo el soporte que me facilitaron.

Un agradecimiento especial a Josselyne Aguilar, Geovanny Chávez, Paolo Delgado, Yerlin Moreira y José Armando Cárdenas del Centro de Innovación Enrique Jiménez Núñez del INTA, su soporte en campo fue vital para el éxito de la investigación, gracias por todo compañeros.

A mis amigos, Kattia, Raudin y toda su familia, por depositar su confianza y estar siempre anuente a colaborar en muchos momentos que necesitaba, su amistad ha sido valiosa y de soporte para culminar este proyecto, mi perpetuo agradecimiento.

A mi amigo Cristian Ríos, mi hermano, que la vida te premie todo el apoyo y motivación que tuviste conmigo durante esta experiencia, ya son más de 17 años de compartir metas, y este trabajo te incluye.

Finalmente, a mi amigo Jorge Fuentes Abarca (qepd); cuando estaba planeando cursar mis estudios de posgrado te mencioné que usaría un RPAS, gracias por convencerme de hacer el proyecto en Cañas, porque sé que en cada vuelo me acompañaste, un abrazo hasta donde estés.

Este Trabajo Final de Graduación fue aceptado por el Comité de Gestión Interinstitucional del Programa (CI) de Maestría Profesional en Sistemas de Información Geográfica y Teledetección, de la Universidad de Costa Rica (UCR) y la Universidad Nacional (UNA), como requisito para optar por el grado de Magíster en Sistemas de Información Geográfica y Teledetección.

MSc. Francisco Rodríguez
Representante del Decano del Sistema de Estudios de Posgrado

Mag. Melvin Lizano Araya
Tutor

MSc. Jorge Claudio Vargas Rojas
Asesor

Dr. Nevio Bonilla Morales
Asesor

MSc. Ramón Masís Campos
Representante del Programa de Posgrado en Geografía

Kevin Carrillo Montoya
Sustentante

Índice General

Resumen.....	x
Capítulo 1.....	1
1.1 Introducción	1
1.2. Justificación	3
1.3. Problema de investigación.....	5
1.4 Objetivos.....	5
1.4.1 Objetivo general.....	5
1.4.2 Objetivos específicos.....	5
Alcances del proyecto.....	6
Limitaciones.....	7
Capítulo 2. Marco teórico.....	8
2.1 Características del sorgo	8
2.2 El fenotipado en campo en los programas de mejora genética	10
2.3 Teledetección.....	12
2.4 Plataformas y sensores remotos.....	14
2.4.1 Sistemas de aeronaves pilotadas de manera remota (RPAS).....	15
2.4.2 Alturas de vuelo con RPAS.....	16
2.5 Proceso fotogramétrico de imágenes multiespectrales obtenidas con RPAS.....	16
2.6 Modelo de regresión Random Forest.....	18
2.7 Respuesta espectral y predicción de rendimiento de cultivos.....	20
Capítulo 3. Marco metodológico.....	22
3.1. Localización del estudio.....	22
3.2. Material genético.....	22
3.3. Diseño experimental	23
3.4. Manejo agronómico	23
3.4.1. Siembra	23

3.4.2. Nutrición	24
3.5. Características de la plataforma y del sensor	25
3.6. Proceso de captura de datos con RPAS.....	26
3.7. Muestreo de campo	28
3.7.1. Altura de planta.....	28
3.7.2. Rendimiento de materia seca (MS) de forraje	29
3.7.3. Rendimiento de grano.....	29
3.8. Proceso fotogramétrico.....	30
3.8.1. Puntos de control (corrección geométrica)	31
3.8.2. Nube de puntos densa y malla	32
3.8.3. Calibración radiométrica	32
3.8.4. Generación del MDT, MDS y ortomosaico	34
3.9. Cálculo de índices espectrales	35
3.10. Construcción de vectores y segmentación de suelo.....	36
3.11. Extracción de datos del MDS-MDT.....	37
3.12. Extracción de datos multiespectrales para cada vuelo	38
3.13. Predicción de la altura de planta.....	38
3.14. Asociación entre altura real de planta y estimada por el proceso fotogramétrico.....	38
3.15. Asociación entre los datos de rendimiento de biomasa y grano con los índices espectrales	39
3.16. Modelos de predicción de biomasa y grano.....	39
Capítulo 4. Resultados y discusión	41
4.1. Predicción de altura de planta	41
4.2. Rendimiento de biomasa seca.....	45
4.2.1. Correlación temporal de índices o bandas espectrales y rendimiento de biomasa seca.....	46
4.2.2. Modelos de predicción de rendimiento de biomasa seca	49
4.3. Rendimiento de grano.....	53
4.3.1 Correlación temporal de índices espectrales y rendimiento de grano... 53	

4.3.2. Modelos de predicción de rendimiento de grano	55
Conclusiones.....	58
Recomendaciones	59
Literatura Citada.....	61
Anexos	76



Autorización para digitalización y comunicación pública de Trabajos Finales de Graduación del Sistema de Estudios de Posgrado en el Repositorio Institucional de la Universidad de Costa Rica.

Yo, Kevin Carrillo Montoya, con cédula de identidad 504070831,

en mi condición de autor del TFG titulado

Predicción de altura de la planta y rendimiento del sorgo mediante datos multiespectrales y fotogrametría de RPAS

Autorizo a la Universidad de Costa Rica para digitalizar y hacer divulgación pública de forma gratuita de dicho TFG a través del Repositorio Institucional u otro medio electrónico, para ser puesto a disposición del público según lo que establezca el Sistema de Estudios de Posgrado. SI NO *

***En caso de la negativa favor indicar el tiempo de restricción: _____ año (s).**

Este Trabajo Final de Graduación será publicado en formato PDF, o en el formato que en el momento se establezca, de tal forma que el acceso al mismo sea libre, con el fin de permitir la consulta e impresión, pero no su modificación.

Manifiesto que mi Trabajo Final de Graduación fue debidamente subido al sistema digital Kerwá y su contenido corresponde al documento original que sirvió para la obtención de mi título, y que su información no infringe ni violenta ningún derecho a terceros. El TFG además cuenta con el visto bueno de mi Director (a) de Tesis o Tutor (a) y cumplió con lo establecido en la revisión del Formato por parte del Sistema de Estudios de Posgrado.

FIRMA ESTUDIANTE

Nota: El presente documento constituye una declaración jurada, cuyos alcances aseguran a la Universidad, que su contenido sea tomado como cierto. Su importancia radica en que permite abreviar procedimientos administrativos, y al mismo tiempo genera una responsabilidad legal para que quien declare contrario a la verdad de lo que manifiesta, puede como consecuencia, enfrentar un proceso penal por delito de perjurio, tipificado en el artículo 318 de nuestro Código Penal. Lo anterior implica que el estudiante se vea forzado a realizar su mayor esfuerzo para que no sólo incluya información veraz en la Licencia de Publicación, sino que también realice diligentemente la gestión de subir el documento correcto en la plataforma digital Kerwá.

Resumen

El aumento de la población mundial proyectado para los próximos años incrementa el desafío de asegurar una producción de alimentos suficiente. Una de las medidas para solventar la demanda de alimentos es el mejoramiento genético de cultivos que provee constantemente nuevas variedades con mayor rendimiento y características deseables. Sin embargo, los programas de mejora genética necesitan de nuevas tecnologías que le permitan acelerar los procesos de fenotipado en campo. El objetivo de este estudio fue predecir la altura de la planta y rendimiento del sorgo mediante datos multiespectrales y fotogrametría de RPAS (Remote pilot aircraft system) en la Región Chorotega de Costa Rica. Se utilizaron seis materiales de sorgo con ocho repeticiones cada uno, dispuestos en un diseño completamente aleatorizado. Se efectuaron vuelos en diferentes etapas fenológicas del cultivo con un sensor multiespectral y se generaron índices de vegetación, así como modelos digitales de terreno (MDT) y de superficie (MDS). También se midió manualmente la altura de la planta y se cuantificó el rendimiento de biomasa y de grano. Se realizaron análisis de correlación para comparar la altura real de planta y la derivada por el sensor; de la misma manera se correlacionó el rendimiento con los índices de vegetación. Posteriormente se realizaron predicciones de las variables de rendimiento con un modelo Random Forest. Se encontraron correlaciones fuertes entre la altura de planta real y la estimada a partir de los MDT y MDS ($r=0,75$) para la etapa de crecimiento más temprana, mientras que para las etapas finales del cultivo el coeficiente de determinación fue mayor, $R^2=0,85$ y $RMSE= 0,14$ m. Se identificó que la etapa fenológica de estado de bota (completo desarrollo de panícula y máxima superficie foliar), es la más precisa para la predicción de biomasa $r=0,75$, $RMSE 1,40$ t.ha⁻¹, donde destacaron los índices NDRE e IKAW; asimismo, la inclusión de la altura de planta mejoró la predicción de biomasa en todos los modelos. Por otro lado, los índices NDRE, CIRE y REDVI fueron las variables de mayor importancia y produjeron mayor precisión en la predicción del rendimiento de grano en la etapa fenológica de grano pastoso ($r=0,85$, $RMSE= 1,20$ t.ha⁻¹). Los resultados demostraron que los modelos derivados de sensores en RPAS predicen con precisión la altura de la planta del sorgo. Además, el uso de índices de vegetación con modelos de aprendizaje automático posee potencial como herramienta de seguimiento del cultivo para los fitomejoradores en los programas de mejora genética.

Índice de cuadros

Cuadro 1. Análisis químico del suelo del área experimental utilizada, Estación Experimental Enrique Jiménez Núñez, Cañas, Guanacaste, Costa Rica. 2023.	24
Cuadro 2. Cantidad de macronutrientes aplicados para la nutrición del cultivo, Cañas, Guanacaste, 2023.	25
Cuadro 3. Bandas espectrales de la cámara Micasense Altum serie AL05 o superior.	26
Cuadro 4. Condiciones climáticas y propósito de cada vuelo durante las diferentes etapas fenológicas del sorgo, Cañas, Guanacaste, 2023.	27
Cuadro 5. Fórmulas para el cálculo de variables de rendimiento en sorgo, Cañas, Guanacaste, 2023.	30
Cuadro 6. Índices de vegetación utilizados en la investigación, Cañas, Guanacaste, 2023.	35
Cuadro 7. Correlación de Spearman entre bandas e índices espectrales y el rendimiento de biomasa seca para el primer ciclo de cultivo, Cañas, Guanacaste, 2023.	46
Cuadro 8. Modelos de predicción de biomasa seca de sorgo según etapa fenológica, Cañas, Guanacaste, 2023.	49
Cuadro 9. Correlación de spearman entre bandas e índices de vegetación y el rendimiento de grano de sorgo, Cañas, Guanacaste, 2023.	54
Cuadro 10. Modelos de predicción de grano de sorgo según etapa fenológica, Cañas, Guanacaste, 2023.	55

Índice de figuras

Figura 1. Etapas fenológicas del cultivo de sorgo.	9
Figura 2. Espectro electromagnético (Longitud de onda en metros).	13
Figura 3. Ejemplos de sensores remotos utilizados en agricultura.	14
Figura 4. Ubicación del sitio de la investigación, Cañas, Guanacaste, 2023. ..	22
Figura 5. Croquis de campo del diseño del experimento, Cañas, Guanacaste, 2023.	23

Figura 6. Pantalla de la consola de DJI Pilot en misión de vuelo, CIA-EJN, Cañas, Guanacaste, 2023.	27
Figura 7. A: RPAS Matrice 210 con cámara AL05 y antena RTK; B: panel de reflectancia; C: ejemplo de toma de imágenes del panel de reflectancia, Cañas, Guanacaste, 2023.	28
Figura 8. Descripción de la medición de altura de planta de sorgo en campo. Panel a: hoja expuesta, panel b: panoja, Cañas, Guanacaste, 2023.	29
Figura 9. (a) Proceso de corrección geométrica con puntos de control de campo; (b) puntos corregidos, Cañas, Guanacaste, 2023.	31
Figura 10. Construcción de nube de puntos densa y malla del sitio experimental, Cañas, Guanacaste, 2023.	32
Figura 11. Proceso de calibración radiométrica de las imágenes multiespectrales.	33
Figura 12. Resumen del flujo de trabajo para la segmentación de suelo. Algoritmo de clasificación Random Forest, Cañas, Guanacaste 2023.	37
Figura 13. Resumen metodológico de la investigación.	40
Figura 14. Box plot de altura de planta según días después de la siembra, Cañas, Guanacaste, 2023.	41
Figura 15. Correlaciones de altura de planta medida manualmente y altura derivada del sensor según días después de la siembra; Panel A: 42 DDS, Panel B: 83 DDS, Panel C: 193 DDS, Cañas, Guanacaste, 2023.	42
Figura 16. Valores reales y predicciones de altura de planta para el primer ciclo del cultivo y soca, Cañas, Guanacaste, 2023.	43
Figura 17. Box plot de rendimiento de biomasa seca según ciclo de cultivo y genotipo; Panel A: Primer ciclo, Panel B: Soca, Cañas, Guanacaste, 2023.	45
Figura 18. Matriz de correlación de spearman entre índices o bandas espectrales en etapa de grano lechoso y el rendimiento de biomasa seca para el ciclo de soca; PS: Peso seco de biomasa, Cañas, Guanacaste, 2023.	47
Figura 19. Correlación entre altura de planta derivada del sensor y el rendimiento de biomasa y grano; Panel a: primer ciclo de cultivo; Panel b: soca; PS: Peso seco, Cañas, Guanacaste, 2023.	48
Figura 20. Predicción de biomasa seca con el algoritmo Random Forest incluyendo los índices espectrales y la altura del cultivo, Cañas, Guanacaste.	50

Figura 21. Importancia de variables en el modelo 2 sobre las predicciones de biomasa seca al final del primer ciclo de cultivo, Cañas, Guanacaste, 2023. ...	51
Figura 22. Box plot de rendimiento de grano seco según genotipo de sorgo, Cañas, Guanacaste, 2023.	53
Figura 23. Importancia de variables sobre las predicciones de rendimiento de grano mediante el modelo Random Forest, Cañas, Guanacaste, 2023.....	56

Lista de abreviaturas

CIA: Centro de Innovación Agropecuaria
CSV: Archivo separado por comas (Comma Separated Values)
INTA: Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria
LANDSAT: LAND=tierra y SAT=satélite
MDS: Modelo Digital de Superficie
MDT: Modelo Digital de Terreno
NASA: La Administración Nacional de Aeronáutica y el Espacio de Estados Unidos
RPAS: Remote pilot aircraft system
RF: Random Forest
SIG: Sistemas de Información Geográfica
GCP: Ground control points (por sus siglas en inglés)
IGN: Instituto Geográfico Nacional de Costa Rica
TIFF: Tagged Image File Format
ML: Machine learning
RTK: Real Time Kinematic
IV: Índice de vegetación
RMSE: Raíz del error cuadrático medio
BCC: Índice de Coordenada cromática azul
CARI: Relación borde rojo
CIRE: Índice de clorofila de borde rojo
CVI: Índice de vegetación de clorofila
DVI: Índice de diferencia de vegetación

GCI: Índice de clorofila verde
GLI: Índice de verdor de hojas
GNDVI: Índice de diferencia normalizada de vegetación verde
IKAW: Índice de Kawashima
NDRE: Índice de diferencia normalizada de borde rojo
NDVI: Índice de diferencia normalizada de vegetación
RCC: Índice de Coordenada cromática roja
RDVI: Índice de diferencia de vegetación renormalizada
REDVI: Índice de diferencia de vegetación de borde rojo
RGRI: Índice de relación rojo-verde
SAVI: Índice de vegetación ajustado al suelo
SR: Cociente simple

Capítulo 1

1.1 Introducción

La seguridad alimentaria es esencial para garantizar el bienestar de la población mundial mediante el acceso y la disponibilidad de alimentos seguros y nutritivos. Las ciencias agroalimentarias enfrentan el gran reto de asegurar que la producción de cultivos sea suficiente para satisfacer las necesidades de una población humana en crecimiento. Se proyecta que la población mundial alcanzará los 9,8 billones para el año 2050 (United Nations [UN], 2017).

El sorgo es considerado a nivel mundial como un grano de seguridad alimentaria en conjunto con otros como el maíz, trigo, arroz y cebada debido a su alto valor nutricional para la alimentación humana y animal (Orozco Barrantes & Sánchez Ledezma, 2018). Sin embargo, desafíos como el cambio climático, la degradación ambiental y el crecimiento demográfico amenazan constantemente la producción de cereales. Esto pone en riesgo la seguridad alimentaria tanto a nivel global como local (Hagen et al., 2022).

Recientemente, se han adaptado algunos procesos para superar los desafíos de la producción de cultivos. Entre estos, se incluyen la siembra de materiales con mayor rendimiento productivo, adaptados a condiciones adversas a partir del mejoramiento genético, además del ajuste espacio-temporal de las aplicaciones de pesticidas, el uso de sensores remotos acoplados a aeronaves y la teledetección (Peng et al., 2020).

Los Sistemas de Aeronaves Pilotadas Remotamente (RPAS), por sus siglas en inglés) son equipos que operan de forma autónoma y en algunas ocasiones controlados por un operador humano. Estas plataformas se han convertido en un enfoque prometedor para evaluaciones agrícolas porque permiten la medición no destructiva del estado de crecimiento de los cultivos y con mejor resolución temporal (Bendig et al., 2015). Además, estos equipos se han utilizado en otros

campos, como la seguridad y el monitoreo ambiental, debido a su capacidad para operar en entornos de difícil acceso (Barnas et al., 2019).

Por otra parte, la mejora genética de cultivos desempeña un papel fundamental en la búsqueda de soluciones para aumentar la producción de alimentos y asegurar su calidad y disponibilidad. Este proceso conlleva la aplicación de técnicas y tecnologías innovadoras para desarrollar variedades vegetales con características mejoradas. Los rasgos mejorados pueden incluir un mayor rendimiento, resistencia a enfermedades, tolerancia a sequía, estrés hídrico o un alto contenido nutricional (Aswini et al., 2023).

En términos generales, los programas de mejora genética involucran la evaluación (fenotipado) de cientos de plantas. Estos procesos de valoración son continuos hasta realizar finalmente una selección de los mejores materiales que podrían ser liberados para la utilización de los productores. La duración de este proceso depende de muchos factores, pero podría superar los siete años para tener un material mejorado con alguna característica requerida (Hall & Richards, 2013; Watt et al., 2020).

En este sentido, diversos autores han adoptado nuevas tecnologías de fenotipado mediante sensores acoplados en RPAS. Estos sensores capturan imágenes para obtener distintos tipos de información relacionada con el desarrollo de los cultivares. Lo anterior, permite a los investigadores en mejora genética tener una alternativa para recolectar más rápidamente información relacionada al desarrollo de los genotipos en distintas condiciones edafoclimáticas (Araus & Kefauver, 2018; Chivasa et al., 2020; Zhang & Kovacs, 2012).

Los RPAS han destacado porque ofrecen una mayor resolución espacial que los satélites, así como una recolección de datos más eficiente y, en algunos casos, más rentable (Shi et al., 2016). La utilización de estas tecnologías permite calcular la temperatura del dosel e índices espectrales, como la diferencia normalizada de borde rojo (NDRE) y la diferencia normalizada de vegetación

(NDVI). Estos índices son indicadores claves del estado de salud, vigor y desarrollo de las plantas (Yang et al., 2017).

Además, los rasgos geométricos tales como altura de la planta, desarrollo foliar, biomasa y rendimiento de los cultivos, pueden estimarse con el uso de estos sensores. Por ejemplo, para la altura de planta se puede derivar con base en un modelo digital de superficie (MDS) o de terreno (MDT) así como el análisis de clasificación de imágenes y modelos de regresión. Lo anterior, convierte a estas herramientas geoespaciales en un insumo de importancia para la gestión de los programas de mejora genética y sistemas productivos (Li et al., 2015).

1.2. Justificación

El fenotipado es un componente esencial en los procesos de mejora genética de los cultivos, ya que refleja la expresión de los factores genéticos, edafoclimáticos y su interacción con variables de rendimiento, como la biomasa o la tolerancia al estrés abiótico y biótico (Neilson et al., 2015). Sin embargo, los programas de mejora genética a menudo enfrentan limitaciones en cuanto a la velocidad y la facilidad para obtener grandes cantidades de información fenotípica de los ensayos en campo. Estas restricciones pueden afectar la eficiencia y la efectividad del proceso de selección y el desarrollo de nuevas variedades (Gano et al., 2021).

En la actualidad, en el país aún se depende en gran medida de muestreos destructivos y valoraciones visuales para la medición de biomasa y altura de planta (variables importantes en el fenotipado); lo anterior puede ser un reto logístico en costo y tiempo para los programas de mejora genética (Mbaye et al., 2021). Estos enfoques han sido valiosos, sin embargo, pueden existir subjetividades en algunas valoraciones, principalmente en técnicas visuales.

El uso de sensores multiespectrales acoplados en RPAS para el fenotipado de cultivos representa una innovación en la investigación científica. Esta tecnología permite a los mejoradores genéticos e investigadores en general realizar estudios más detallados sobre la respuesta y la variabilidad genética, para optimizar los

protocolos experimentales. Además, su implementación podría reducir significativamente los costos operativos al disminuir la necesidad de mano de obra intensiva y permitir un monitoreo de grandes áreas (Araus & Kefauve, 2018). En los últimos años estos equipos han tenido una gran adopción como una alternativa efectiva para la predicción del rendimiento y otras variables de importancia de los cultivos a lo largo de un período, lo que facilita la evaluación precisa y oportuna (Masjedi et al., 2020).

Los datos de teledetección generados por los sensores acoplados en RPAS se han utilizado como variables regresoras en modelos de aprendizaje automático para desarrollar predicciones de rasgos fenotípicos como el rendimiento de biomasa, cobertura vegetal, entre otros (Janga et al., 2023). Por lo tanto, evaluar el uso de estos sensores aerotransportados podría aportar diferentes beneficios a los fitomejoradores.

La evaluación del uso de sensores aerotransportados en un programa de mejora genética local puede optimizar los tiempos de recopilación de datos en campo, debido a que reduce la necesidad de realizar mediciones manuales extensivas para la selección de líneas mejoradas con características agronómicas superiores. En adición, estas tecnologías facilitarían el monitoreo de más área, lo que permite a los fitomejoradores evaluar más cantidad de genotipos en un periodo determinado. Además, proveen mayor precisión y objetividad en comparación con las mediciones manuales que pueden estar sujetas a errores humanos y variabilidad. Lo anterior permitiría contribuir de manera indirecta a la seguridad alimentaria nacional al optimizar los procesos para la liberación de nuevas variedades.

1.3. Problema de investigación

Ante el cambio climático, el aumento en la competitividad del sector agrícola y con el propósito de fortalecer la seguridad alimentaria, se hace necesario que los programas de mejora genética optimicen los procesos de trabajo para obtener nuevos materiales adaptados más rápidamente. En el contexto local, los investigadores en mejora genética requieren nuevas tecnologías que le permitan monitorear los campos de evaluación y tomar decisiones de manera oportuna, además de considerar la variabilidad espacial y temporal de los cultivares.

El programa de mejora genética en sorgo del CIA-Enrique Jiménez Núñez del INTA de Costa Rica carece de estudios sobre nuevos métodos de fenotipado con técnicas geoespaciales que le permitan tener información base para la creación de herramientas para la toma de decisiones en momentos específicos, lo que permitiría acelerar los procesos y obtener variedades mejoradas en un menor tiempo.

1.4 Objetivos

1.4.1 Objetivo general

Predecir la altura de planta y el rendimiento del sorgo mediante el análisis de datos multiespectrales y fotogrametría obtenidos a partir de sensores acoplados en Sistemas de Aeronaves Pilotadas Remotamente (RPAS) en la Región Chorotega de Costa Rica.

1.4.2 Objetivos específicos

- Determinar rasgos espectrales de rendimiento y modelos fotogramétricos de altura de planta del sorgo a partir de sensores remotos acoplados en RPAS.

- Evaluar la altura de planta y el rendimiento de biomasa y grano del cultivo de sorgo mediante muestreos manuales de campo.
- Predecir el rendimiento de biomasa y grano, así como la altura de la planta del sorgo mediante la comparación de datos multiespectrales y fotogramétricos con datos de campo.

Delimitación espacio-temporal

El proyecto de investigación se ejecutó dentro del marco del programa de mejora genética del cultivo de sorgo; el programa de mejora genética de sorgo buscar liberar nuevas variedades que se adapten a las necesidades de los productores costarricenses, dentro de los que destacan mayor rendimiento, plantas con mejor estructura y mayor contenido nutricional; dentro del programa se realizan constantemente evaluaciones (fenotipado) de un alto volumen de materiales genéticos en diferentes condiciones agroclimáticas, no obstante, el proyecto se realizó en la época lluviosa del 2023 y la época seca del 2024 específicamente en el CIA Enrique Jiménez Núñez, del INTA ubicado en Cañas Guanacaste dentro del Corredor Seco Centroamericano.

Alcances del proyecto

Los alcances del proyecto se enmarcan en una serie de actividades dentro del programa de mejora genética de sorgo del INTA que incluyeron la recopilación de datos multiespectrales con RPAS en distintos vuelos sobre las etapas fenológicas del cultivo. Los levantamientos tuvieron la rigurosidad adecuada para el correcto procesamiento de las imágenes que generaron datos confiables del estado de desarrollo del cultivo.

Asimismo, se relacionó la información con datos de campo recopilados de forma manual para determinar la eficacia del sensor para los objetivos del estudio. Lo anterior con el propósito de generar información científica para la predicción de

parámetros morfológicos y de rendimiento del cultivo, que permitan en una etapa posterior, incluirse como una herramienta de apoyo para los mejoradores genéticos en la rápida selección de nuevos genotipos adaptados según los requerimientos.

Limitaciones

Una de las mayores limitaciones fue la alta velocidad del viento de la zona en la época seca, lo que provocó alertas en la aeronave para la realización de los vuelos, por lo tanto, información valiosa de las etapas fenológicas de la soca no pudo ser recopilada. Además, el daño por aves en la panoja en el ciclo de soca impidió la medición confiable del rendimiento de grano, es decir, las parcelas estaban bastante afectadas y los datos no son confiables, por lo que los modelos estimados para esta variable fueron únicamente para el primer ciclo del cultivo.

Capítulo 2. Marco teórico

2.1 Características del sorgo

El sorgo (*Sorghum bicolor L*) es una gramínea C4 de la cual se aprovecha casi toda la planta, tanto para producción de grano, forraje y ensilaje en la alimentación animal. Es uno de los cereales de mayor importancia a nivel mundial con una producción para el año 2021 de 64,3 millones de toneladas (FAO, 2021). Es un cultivo de relevancia en la seguridad alimentaria, ya que puede complementar o sustituir al trigo o al maíz en las necesidades alimenticias de la población (Saucedo et al., 2010). Además, este cultivo posee la habilidad de rebrotar después de la cosecha, lo que representa una característica relevante para su utilización como forraje y consecuente reducción de costos de producción (Vinutha et al., 2017).

Para maximizar su rendimiento en cantidad y calidad ya sea para biomasa o grano, es fundamental conocer los requerimientos edafoclimáticos, así como las necesidades de nutrientes y agua. En este sentido, la semilla requiere alta temperatura en el suelo para germinar con un valor mínimo de 15°C y óptimo entre 18-20 °C en los 10 cm superiores del suelo durante al menos tres días (Kazungu et al., 2023; Ajeigbe et al., 2020).

El sorgo tolera altas temperaturas en comparación con otros cereales con un rango de 27° a 30°C para un adecuado crecimiento y desarrollo (Carrasco et al., 2011). Asimismo, este cultivo es más tolerante a las sales alcalinas que otros cereales y, por lo tanto, puede cultivarse en suelos con un pH (medido en H₂O) entre 5,5 y 7,5. Sin embargo, se desarrolla mejor en suelos fértiles, bien drenados y con una cantidad moderada de materia orgánica (Kazungu et al., 2023).

Por otra parte, la fenología del sorgo presenta tres etapas de crecimiento, GS I, GS II, GSIII (Figura 1), con una duración entre 30-35 días según la variedad y las condiciones edafoclimáticas; estas variaciones en el ciclo fenológico son

influenciadas principalmente por la temperatura y en menor grado por la duración del día (Roozeboom & Vara Prasad, 2019).




Figura 1. Etapas fenológicas del cultivo de sorgo.

Nota. Adaptado de Sorghum Growth and Development (p. 1) por I, Ciampitti, 2023, Kansas State University.

La primera etapa fenológica (GS I), se caracteriza por el desarrollo vegetativo y la formación de las hojas; esta etapa es determinante para el tiempo requerido hasta la etapa maduración. Normalmente los materiales de maduración temprana producen un menor número de hojas (~15) que los de media y tardía maduración (~17-19 hojas) respectivamente (Gerik et al., 2003).

La segunda etapa GS II es el periodo de rápido crecimiento donde se desarrolla el área foliar restante (área foliar máxima). La planta acumula aproximadamente el 60% de la materia seca total, desarrolla las estructuras reproductivas de la panoja y continua hasta la floración. Los requerimientos hídricos aumentan en

esta etapa y es considerada el periodo más crítico para la formación del grano (Roozeboom & Vara Prasad, 2019).

La última etapa GS III comienza desde la floración y se centra en la formación de los granos que continúa a la etapa de grano lechoso, donde el grano aún es suave y un líquido lechoso blanco se obtiene al exprimirlo; posteriormente continúa hasta la etapa de grano pastoso que ocurre unos 15-25 días después de la floración. Luego se alcanza la etapa donde los granos se endurecen y las plantas pueden ser más susceptibles al volcamiento debido a un mayor desecamiento (Roozeboom & Vara Prasad, 2019).

Finalmente se culmina en la etapa de madurez fisiológica. Esta etapa se puede identificar cuando una mancha oscura aparece en la porción basal de la semilla, ~110 días después de la siembra (DDS); el tamaño y peso de la misma varía según la capacidad de la planta para acumular biomasa ya que el 85% de la materia seca producida durante este periodo es destinada al grano (Rao et al., 2008).

2.2 El fenotipado en campo en los programas de mejora genética

La mayoría de los programas de mejoramiento genético tienen como objetivo principal incrementar el rendimiento de un cultivo particular en un contexto agrícola determinado (Rakshit & Gomashe, 2013). Sin embargo, existen objetivos específicos que varían según el cultivo, el mercado de consumo y las necesidades de los agricultores, entre otros factores. Por ejemplo, el contenido de proteína en el grano es un objetivo crucial en el mejoramiento del arroz, mientras que el contenido de proteína en la hoja es relevante en cultivos destinados al forraje. De manera similar, la tolerancia a la sequía es esencial en regiones con escasez de agua, mientras que la tolerancia a las inundaciones es crucial en otras áreas (Trethowan, 2014).

En los programas de mejora genética, las actividades de evaluación en campo desempeñan un papel fundamental en la identificación y selección precisa de rasgos deseables en las plantas. Este proceso implica una logística a gran

escala, con cientos de evaluaciones de plantas y múltiples ciclos de cultivo; posterior a estas evaluaciones, se selecciona un grupo reducido de genotipos con potencial para convertirse en variedades comerciales (Rakshit & Bellundagi, 2018).

Entre los rasgos deseables se incluyen la estructura y altura de la planta, el rendimiento, la resistencia a enfermedades y la tolerancia a condiciones ambientales adversas (Rakshit & Bellundagi, 2018). Estos rasgos son características morfológicas o estructurales que pueden medirse y que influyen en el estado de la planta; este proceso de evaluación de estos rasgos a un genotipo en un ambiente específico se denomina fenotipado (Walter et al., 2015).

La altura de la planta es un atributo de gran importancia en el mejoramiento de cultivos, ya que influye significativamente en el rendimiento y la adaptabilidad de las variedades. Una altura de planta óptima puede mejorar la capacidad de las plantas para la captación de luz solar, reduce el riesgo de acame, optimiza el consumo de nutrientes y facilita las prácticas de manejo y cosecha (Moles et al., 2009). En programas de mejora genética, el fenotipado por altura de planta permite desarrollar cultivos que maximicen el rendimiento bajo diferentes condiciones ambientales, lo que asegura la estabilidad y productividad en los sistemas agrícolas (Wang et al., 2018).

Por otra parte, el rendimiento es un factor crucial en el mejoramiento genético del sorgo, ya que determina la productividad y viabilidad económica del cultivo. Un alto rendimiento de grano es esencial para satisfacer la creciente demanda de alimentos, especialmente en regiones donde el sorgo es un cultivo clave debido a su resistencia a la sequía y adaptabilidad (Behera et al., 2022). Mejorar el rendimiento de grano implica desarrollar variedades que no solo produzcan más grano por hectárea, sino que también mantengan una calidad nutricional superior y una resistencia robusta a plagas y enfermedades (Baye et al., 2022).

Asimismo, un parámetro importante es el rendimiento de biomasa que resulta fundamental para la alimentación animal como forraje e inclusive puede funcionar como biocombustible (Stamenković et al., 2020). La biomasa, es el resultado de

la fotosíntesis y de otros mecanismos fisiológicos de la planta. Estos procesos involucran la absorción y el uso de la radiación solar, el agua y los nutrientes minerales. Además, las mediciones de biomasa permiten evaluar el estado de desarrollo de los cultivos y su posterior potencial rendimiento de grano (Johansen et al., 2019).

La integración de tecnologías avanzadas de fenotipado, como la teledetección y el uso de RPAS, ha aumentado la precisión y eficiencia del proceso; lo anterior ha permitido en otras latitudes acelerar el desarrollo de nuevos genotipos con mayor rendimiento, más resilientes y sostenibles frente a los desafíos climáticos y agrícolas actuales (Watt et al., 2020).

2.3 Teledetección

La teledetección es útil para generar información espacial y se aplica en diversos campos de la ciencia, como socioeconómicos, agricultura e ingeniería mecánica (Read & Torrado, 2009). Desde el punto de vista agronómico, permite detectar problemas en los cultivos antes de que puedan identificarse de manera visual. Lo anterior permite a los agricultores enfocar recursos únicamente en las áreas afectadas (Adamchuk et al., 2003).

Los principios básicos de la teledetección son similares a las observaciones visuales. Se basa en que la energía viaja del sol a la tierra en forma de ondas de luz y se diferencian según longitudes de onda (Figura 2) que van desde el pico de una onda hasta el pico de la siguiente dentro del espectro electromagnético (Weiss et al., 2020). Estos datos son procesados y analizados para extraer características y patrones, lo que permite su evaluación y monitoreo.




Figura 2. Espectro electromagnético (Longitud de onda en metros).

Nota: Tomado de Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia, por P. Murillo Sandoval y J. Carbonell González, 2012, Cenicaña.

La espectroscopía se basa en la modificación medible de la radiación al interactuar con las coberturas, lo que está determinado por su composición química. Esta interacción provoca vibraciones en las moléculas, que absorben energía a longitudes de onda específicas y reflejan otras. Este proceso permite estimar la cantidad de moléculas absorbidas, transmitidas o reflejadas (Botero Herrera, 2009). Existen diversos estudios sobre la relación del espectro visible e infrarrojo con las plantas (Saravia et al., 2022; Braga et al., 2021; Li et al., 2015), en éstos se han analizado distintas respuestas morfológicas, además se han determinado la composición y naturaleza de la superficie detectada desde escalas locales a globales según la resolución espacial (Hauser et al., 2021; Alvarez-Vanhard et al., 2021).

2.4 Plataformas y sensores remotos

Los sistemas de teledetección utilizados en agricultura normalmente se diferencian en función de la plataforma utilizada y el tipo de sensor; los sensores se pueden acoplar a plataformas, ya sea satelitales, aviones e inclusive terrestres (Figura 3). Estos últimos pueden ser portátiles, establecidos en campo o ensamblados a maquinaria agrícola, con la característica de mayor proximidad al objeto a detectar en comparación con los aéreos (Sishodia et al., 2020).



Figura 3. Ejemplos de sensores remotos utilizados en agricultura.

Nota: Adaptado de Unmanned Aerial Vehicle-Based Remote Sensing: Techniques, applications, and prospects, por X. Tian-Zhu; X. Gui-Song; Z. Liangpei, 2018.

Las plataformas de satélites y aeronaves tripuladas suelen operar en órbitas fijas o seguir rutas preestablecidas. Sin embargo, en muchas zonas, especialmente en áreas pequeñas, existe una creciente demanda de diversos trabajos de cartografía, actualización de información geográfica, monitoreo y producción agrícola, entre otros. La falta de flexibilidad en las plataformas tradicionales, como satélites y aviones, representan un desafío significativo (Xiang et al., 2019).

Los sensores acoplados a distintas plataformas, capturan imágenes en diferentes bandas del espectro electromagnético (Figura 2), más allá del rango visible al ojo

humano, que incluye el infrarrojo cercano. Al integrar estas imágenes con herramientas de análisis geoespacial, se pueden tomar decisiones más informadas (Wu et al., 2023). La elección de la plataforma depende de los objetivos del estudio, pero de manera general implica un equilibrio entre resolución espacial, temporal, el rendimiento y el costo (Adamchuk et al., 2003).

2.4.1 Sistemas de aeronaves pilotadas de manera remota (RPAS)

Los RPAS se componen de varios tipos que dependen de los requerimientos del usuario. Por ejemplo, los de tipo ala fija se caracterizan por su diseño similar al de los aviones tradicionales, que ofrecen una alta eficiencia en vuelos de largo alcance por su mayor velocidad; lo anterior los hace adecuados para misiones de vigilancia extensiva y cartografía de mayor escala (Tang & Shao, 2015). En contraste, los RPAS de ala rotatoria, como los cuadricópteros, proporcionan una mayor maniobrabilidad y capacidad para realizar vuelos estacionarios, siendo particularmente útiles para inspecciones detalladas y operaciones en entornos más complejos (Dutta & Goswami, 2020).

Los RPAS poseen diversas ventajas desde el punto de vista agrícola. Por ejemplo, mayor flexibilidad de cubrir áreas complejas, maniobrabilidad, economía y seguridad. Además la fácil recolección de datos bajo demanda los caracteriza como un complemento efectivo a las plataformas tradicionales (Xiang et al., 2019). En adición, estos equipos pueden operar en altitudes superiores a los 100 metros, pero depende de las normativas de vuelo de cada país.

Los RPAS de ala fija tienen menos flexibilidad en la integración de sensores en comparación con los multirrotor. Por lo tanto, éstos últimos son más comunes en misiones para fotogrametría aérea de alta resolución. Sin embargo, en los últimos años, estos equipos han sido fabricados en diversas dimensiones, formas y capacidades para adaptarse a las necesidades específicas de cada tarea (Tang & Shao, 2015).

Los RPAS son posiblemente las plataformas más adecuadas para monitoreo de cultivos en el contexto de mejoramiento genético; el uso de esta tecnología permite obtener imágenes de una gran cantidad de parcelas experimentales en un corto período de tiempo, lo que reduce el riesgo de cambios en las condiciones de iluminación que pueden afectar los valores radiométricos (Mir et al., 2019).

2.4.2 Alturas de vuelo con RPAS

La altura para realizar levantamientos multiespectrales con RPAS depende de varios factores, como la resolución espacial requerida, el tipo de sensor, y las características del área de estudio (Njane et al., 2023). A una menor altura, se obtiene mayor resolución espacial, es decir un mejor detalle del área de estudio, lo cual es ideal para estudios de vegetación, análisis de salud de cultivos, y mapeo de pequeñas áreas. Sin embargo, a mayor altura, se cubre un área más extensa en menos tiempo, aunque con menor resolución espacial (Zhang et al., 2020).

En estudio de crecimiento del cultivo de papa con datos espectrales, Njane et al. (2023) no obtuvieron diferencias en el índice de diferencia normalizada de vegetación (NDVI) al evaluar distintas alturas de vuelo. Asimismo, Liu et al. (2023) reportaron diferencias para la predicción de biomasa en sorgo de 3% cuando realizaron los vuelos a una altura de 45 metros ($R^2=0,85$) en comparación con 25 m ($R^2=0,88$). Por lo tanto, es crucial balancear la altura de vuelo con las necesidades de la investigación y las especificaciones del sensor multiespectral para asegurar mayor eficiencia en los levantamientos.

2.5 Proceso fotogramétrico de imágenes multiespectrales obtenidas con RPAS

El proceso de fotogrametría en programas computacionales es en su mayoría automatizado y la única información que necesita ser proporcionada son las imágenes. De manera general el proceso fotogramétrico consta de tres partes. Primero, se crea un modelo de una nube de puntos de baja densidad donde las

características de la escena se identifican en todas las imágenes. Las posiciones de la cámara y de las imágenes se calculan en función de las características del vuelo, además de la geolocalización del modelo (Remondino et al., 2011).

Previo al segundo paso, los puntos de control en tierra tienen gran relevancia cuando se realiza el proceso fotogramétrico y recopilación de datos con sensores acoplados en RPAS (Sanz-Ablanedo et al., 2018). Estos puntos (GCP, ground control points) por sus siglas en inglés, funcionan como referencia conocidos en las imágenes, o en la nube de puntos, de manera que se establece una correcta posición y orientación de los datos (Zeybek et al., 2023). Esta corrección permite crear mapas georreferenciados con un error mínimo en las coordenadas (y,x,z), por lo que los modelos 3D y demás productos son más precisos. (Liu et al., 2022).

Para el segundo paso y según el modelo disperso con base en los puntos de control se genera la nube de puntos (modelo denso). Los algoritmos detrás de estos procesos no son de libre acceso y la documentación detallada paso a paso no está disponible. Sin embargo, los principios y la teoría de esta técnica se pueden consultar en diversos artículos científicos (Pargieła, 2023; James & Robson, 2012). De manera resumida, en ambos pasos, el software calcula automáticamente las posiciones de la cámara, alinea todas las imágenes por ubicación y coincidencia al usar puntos comunes para establecer las posiciones relativas del sensor durante el vuelo (PIX4D, 2017).

Por otra parte, un aspecto importante en el flujo de procesamiento es la calibración radiométrica de las imágenes multiespectrales. Este paso es necesario para poder comparar imágenes multiespectrales tomadas en diferentes tiempos y en diferentes condiciones climáticas (Poncet et al., 2019). En la agricultura, este proceso involucra la eliminación de factores externos de variación, como las condiciones de clima y del sensor con el propósito de obtener medidas más precisas y confiables de las propiedades físicas de los cultivos (Guo et al., 2019)

La calibración radiométrica convierte los píxeles de una imagen en valores absolutos de radiancia espectral. Lo anterior compensa el nivel de negro, la sensibilidad y exposición del sensor y los efectos de la lente (Micasense, 2023). La transformación a reflectancia podría realizarse con base a la irradiancia incidente, estimada mediante modelos de transferencia radiativa atmosférica o con el uso de paneles de reflectancia espectral conocida para calcular los factores y aplicar un método lineal (Aasen et al., 2018). Todos los parámetros utilizados en el modelo se pueden leer desde los metadatos de las imágenes en formato TIFF guardadas por el sensor (PIX4D, 2017).

Finalmente, sobre la base del modelo 3D creado previamente, se pueden generar tres productos el MDT, MDS y el ortomosaico. Un modelo digital del terreno es un modelo topográfico que se utiliza para representar la superficie del suelo mientras que el modelo digital de superficie representa la información sobre vegetación, edificios u otras características por encima del nivel del suelo (Sarkar et al., 2020). La calidad del producto reconstruido depende de factores como las propiedades físicas de los objetos, la iluminación (luz difusa, directa y la posición solar), las condiciones meteorológicas y la configuración del sensor y por último el procesamiento en particular (Seifertm et al., 2019; Probst et al., 2018).

Por otra parte, los datos de reflectancia del suelo pueden incidir en los valores de los índices espectrales calculados, en especial los índices basados en la banda roja en las etapas de crecimiento de los cultivos (Dyson et al., 2019). La segmentación de suelo basada en algoritmos de clasificación supervisada ha generado buenos resultados para formar grupos de píxeles referentes a vegetación y a suelo, y por consiguiente separarlos posteriormente (Liu et al., 2023; Matias et al., 2020).

2.6 Modelo de regresión Random Forest

La técnica de Random Forest es un algoritmo de aprendizaje automático que ha sido utilizado en diversos campos de estudio, por ejemplo, mercado, economía, ingeniería y ciencias ambientales (Espinosa-Zuñiga, 2020; Prasad et al., 2020).

Esta técnica ha sido comparada con otros modelos de machine learning y ha generado una mayor precisión para la predicción del rendimiento de diversos cultivos (Jiva et al., 2023; Jeong et al., 2016). Este modelo selecciona un número aleatorio de muestras durante el proceso de entrenamiento para generar la predicción final mediante el promedio de todos los árboles de decisión (Belgiu & Drăgu, 2016; Liu et al., 2023).

El modelo divide los datos en dos partes, entrenamiento y validación y la proporción de los datos puede variar por ejemplo entre 70/30 u 80/20 respectivamente. Luego, se realiza una búsqueda aleatoria en un rango de valores para los parámetros (ntree: número de árboles y mtry: variables en cada nodo) (Dutta et al., 2019). Finalmente, el modelo ajusta automáticamente sus parámetros durante el entrenamiento para minimizar el error lo que genera predicciones más precisas en los datos de validación (Prasad et al., 2006).

Asimismo, este modelo provee medidas de la importancia de las variables integradas para la predicción de la variable de interés. Las medidas de importancia brindan información valiosa para detectar la magnitud del efecto de cada una de las variables regresoras sobre la variable respuesta (Strobl et al., 2008). Además, para evaluar el desempeño del modelo se consideran el coeficiente de correlación (r) entre los valores observados y los predichos, así como el coeficiente de determinación R^2 , el cual indica un valor cercano a uno como un mejor ajuste y un valor cercano a cero como un menor ajuste (Liu et al., 2023).

Las otras medidas de desempeño como la raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE) deben ser mínimas entre los modelos seleccionados si se deben hacer comparaciones, es decir los menores valores del RMSE y MAE indican el mejor modelo para predecir la variable de interés (Dutta et al., 2019).

2.7 Respuesta espectral y predicción de rendimiento de cultivos

La predicción del rendimiento de los cultivos es esencial para planificar y tomar decisiones. La experimentación para la predicción del rendimiento por medio de datos de teledetección, ha estado en curso desde antes del lanzamiento en 1972 del primer Satélite de Tecnología de Recursos Terrestres de la NASA (ERTS-1, ahora conocido como Landsat) (Adamchuk et al., 2003).

Actualmente, las imágenes de detección remota se aplican para predecir el rendimiento del cultivo en función de índices de vegetación (IV). Estos, son calculados a partir de combinaciones de bandas espectrales como indicadores de cambios estructurales o químicos en las plantas, mediante las variaciones del espectro de reflectancia (Peña et al., 2018).

En el contexto de los cultivos, es crucial tener en cuenta diversos factores, como la posición geográfica, que incluye la pendiente y la orientación del terreno. Además, se debe tomar en cuenta las características morfológicas de las plantas, como su altura, arquitectura y área foliar. También, resulta fundamental considerar las propiedades reflectivas de las hojas, las cuales pueden variar según el desarrollo fenológico, la forma y el contenido de humedad en el momento de la medición (Martínez & Solis, 2018).

En el caso de la predicción de biomasa, se deduce del contraste en la reflectividad espectral especialmente del rojo e infrarrojo cercano (IR); a mayor contraste entre dichas bandas mayor será el vigor de la masa vegetal analizada (Chuvienco Salinero, 2010). Asimismo, el IR está relacionado con la reflectancia difusa de la celulosa y bandas de agua (Kumar et al., 2023).

En una investigación en el cultivo de cebada a partir mediciones manuales e imágenes digitales, Brocks & Bareth (2018) obtuvieron correlaciones para altura de planta de 0,80, que se incluyó en un modelo lineal para predecir biomasa ($R^2=0,72$). Asimismo, en maíz, Saravia et al. (2022) obtuvieron correlaciones fuertes (0,84; 0,78 y 0,88) entre el rendimiento de grano y los índices de vegetación NDVI, el índice de absorción de clorofila modificada (MCARI) y el

índice de vegetación ajustado al suelo (SAVI) respectivamente. Los autores revelaron que esta variable podría estimarse mejor con el uso de estos índices en etapa de llenado de granos.

En el cultivo de arroz, Stavrakoudis et al. (2019) lograron predecir la biomasa ($R^2=0,80$) al incluir 35 IV calculados a partir de imágenes multiespectrales provenientes de RPAS. Por otro lado, Yue et al. (2017) lograron mejores predicciones de biomasa ($R^2=0,74$) en el cultivo de trigo al combinar la información sobre la altura de la planta con los índices NDVI, el índice mejorado de vegetación (EVI) y el índice de proporción de la vegetación (RVI).

En el caso del sorgo, Li et al. (2022), combinaron variables del dosel, altura de planta e índices espectrales y con un modelo de regresión de soporte de vectores (SVR), obtuvieron moderadas predicciones para biomasa fresca ($R^2=0,53$). Los autores reportaron que el modelo fue más confiable al transformar la biomasa como un índice de tolerancia a la sequía, que es comúnmente utilizado en los programas de mejoramiento genético para detección de genotipos tolerantes a esta condición. Además, la capacidad predictiva de índices de vegetación para el cultivo de sorgo en distintas épocas combinadas con medidas de altura del dosel fue estudiada por Nakasagga et al. (2022) quienes obtuvieron mejores predicciones con modelos de aprendizaje automático (>70%) que la regresión lineal simple (<10%) para las variables, conteo de plantas, materia fresca y seca.

Por otra parte, diversos autores han estimado la altura con MDS (modelos digitales de superficie) en cebada (Aasen et al., 2015), trigo (Yue et al., 2017) y sorgo (Zhao et al., 2021). Por ejemplo, De Souza et al. (2017) obtuvieron correlaciones en el cultivo de caña de azúcar ($r=0,5$) con modelos de superficie de cultivo (MDS) generados a partir de imágenes de alta resolución y modelos digitales de superficie del terreno.

Capítulo 3. Marco metodológico

3.1. Localización del estudio

El estudio se realizó en el CIA-Enrique Jiménez Núñez del INTA ubicado en Cañas, Guanacaste (Figura 4), en las coordenadas geográficas centrales 10° 20' 39.73 norte y -85° 08' 8.62 oeste, durante los meses de setiembre de 2023 a abril de 2024. El sitio posee promedios de temperatura y precipitación de 28 °C y 1600 mm, respectivamente, y se encuentra ubicada a 14 m s. n. m., dentro de la zona de vida Bosque húmedo premontano (Ministerio de Ambiente y Energía, 2022).

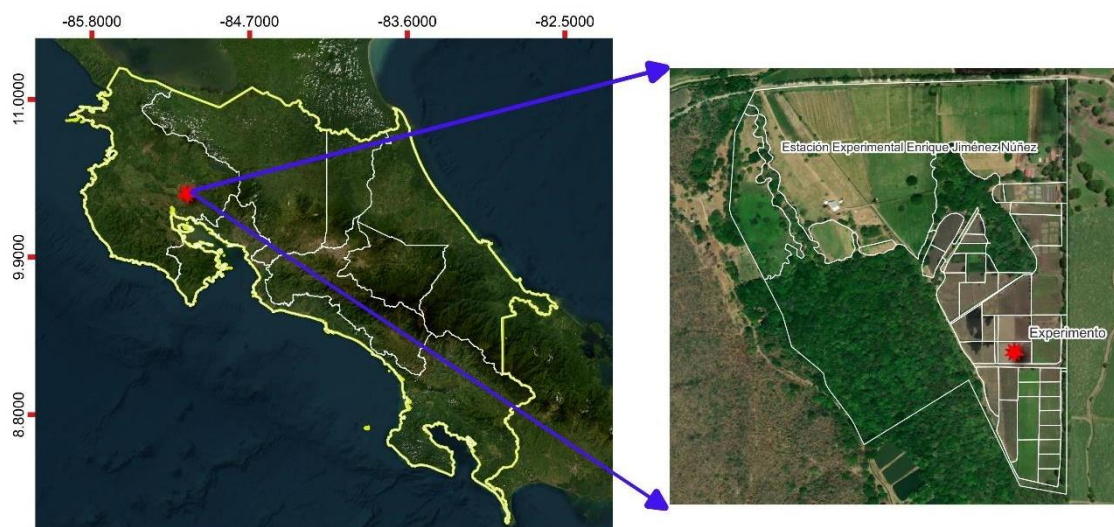


Figura 4. Ubicación del sitio de la investigación, Cañas, Guanacaste, 2023.

3.2. Material genético

Se utilizaron los materiales de *sorgo* BMR-0936, PCR-3-22, CENTA CF, CENTA RCY y Sureño. Asimismo, se evaluó la variedad sorgo negro forrajero (*Sorghum alnum*) utilizada comúnmente por los productores a nivel nacional.

3.3. Diseño experimental

Se establecieron en el campo 48 unidades experimentales (UE) en un diseño completamente aleatorizado correspondientes a ocho repeticiones por genotipo (Figura 5). Cada UE estuvo compuesta por cuatro surcos de cinco metros de longitud y un espaciamiento entre surcos de 70 cm para un área efectiva de 14 m². La separación entre las parcelas fue de 120 cm.




Figura 5. Croquis de campo del diseño del experimento, Cañas, Guanacaste, 2023.

3.4. Manejo agronómico

3.4.1. Siembra

El terreno se preparó de forma convencional con rastra rompedora y rastra liviana para mejorar las propiedades físicas del suelo. La siembra se realizó manualmente a doble surco por camellón, con una densidad de 20 kg de semilla ha⁻¹, la semilla se depositó sobre el surco a una profundidad no mayor a cuatro centímetros; se realizó un control químico de malezas postemergente y limpiezas con motoguadaña.

3.4.2. Nutrición

Previo a la siembra, se realizó un análisis químico del suelo (Cuadro 1) con el fin de ajustar el plan de nutrición según los requerimientos del cultivo; los requerimientos nutricionales del sorgo para una producción estimada de 6,5 t ha⁻¹ de grano son de 190, 30, 108, 20, 18 y 21 kg ha⁻¹ de nitrógeno(N), fósforo (P), potasio(K), calcio (Ca), magnesio y azufre respectivamente (Whitney, 1998). Asimismo, las dosis de nitrógeno de 210–280 kg ha⁻¹ en sorgo, proporcionan las mayores respuestas en el rendimiento de biomasa seca consistentes con una buena calidad nutricional para la producción de forraje con fines de alimentación animal (Restelatto et al., 2014).

Cuadro 1. Análisis químico del suelo del área experimental utilizada, Estación Experimental Enrique Jiménez Núñez, Cañas, Guanacaste, Costa Rica. 2023.

KCl-Olsen Modificado	pH H ₂ O	ACIDEZ	cmol(+) L ⁻¹			%		mg L ⁻¹				
			Ca	Mg	K	CICE	SA	P	Zn	Cu	Fe	Mn
Nivel crítico	5,50	0,50	4,00	1,00	0,20	5,00	10	10,00	3,00	1,00	10,00	5,00
Suelo	6,60	0,15	12,40	4,40	0,12	16,92	0,90	13,00	2,80	19,90	206,50	10,50

Nota: Elaboración propia, 2024

En este sentido, se realizaron tres fertilizaciones al cultivo según se muestra en el Cuadro 2. Además, se efectuaron dos aplicaciones foliares para suplir la demanda de micronutrientes.

Cuadro 2. Cantidad de macronutrientes aplicados para la nutrición del cultivo, Cañas, Guanacaste, 2023.

Fuente	Total de nutrientes aplicados (kg ha ⁻¹)			DDS
	N	P ₂ O ₅	K ₂ O	
10-30-10	37	111	37	0
Urea + 10-30-10	173	89	30	26
Urea	68	----	---	40

Nota: Elaboración propia, 2024

3.5. Características de la plataforma y del sensor

Para los vuelos, se utilizó un RPAS multirrotor DJI Matrice 210 RTK (Real Time Kinematic). Este RPAS es compatible para el acople con diversos sensores y su uso en diferentes estudios, por ejemplo, mapeo de terrenos, inspección de infraestructuras, monitoreo ambiental, entre otros. Además, cuenta con un sistema de posicionamiento RTK que proporciona una precisión de posicionamiento centimétrica, lo que es esencial para alivianar los flujos de trabajo posteriores.

Un sensor Micasense Altum 05 fue acoplado al RPAS para la recolección de datos multiespectrales. Este sensor está equipado con seis bandas espectrales, Rojo, Verde, Azul, Borde Rojo, Infrarrojo Cercano y Térmico (Cuadro 3). En el Anexo 1 se presenta con más detalle las especificaciones de la lente y las imágenes.

Cuadro 3. Bandas espectrales de la cámara Micasense Altum serie AL05 o superior.

Nombre	Longitud de onda central	Ancho de banda
Azul	475 nm	32 nm
Verde	560 nm	27 nm
Rojo	668 nm	14 nm
Borde rojo	717 nm	12 nm
Infrarrojo cercano	842 nm	57 nm
LWIR	11 μ m	6 μ m

Nota: Adaptado de (MicaSense, 2020)

3.6. Proceso de captura de datos con RPAS

Primeramente, se colocaron marcas de control de campo y se realizó un levantamiento de cinco puntos de control (uno en cada vértice del área y otro en el centro) con una estación geodésica marca GEOMAX modelo Zenith40 para el posterior ajuste del ortomosaico y corrección geométrica. En el caso de los levantamientos de datos multiespectrales, se realizó un plan de vuelo con parámetros establecidos mediante la aplicación DJI Pilot que cubrió toda el área experimental (Figura 6) y un buffer de 50 metros con el propósito de garantizar la calidad del proceso fotogramétrico.



Figura 6. Pantalla de la consola de DJI Pilot en misión de vuelo, CIA-EJN, Cañas, Guanacaste, 2023.

El RPAS con los parámetros de vuelo operó de forma autónoma. Los vuelos, se realizaron a una altura de 45 metros en distintas etapas del crecimiento del cultivo (Cuadro 4), a una velocidad de 3 m/s, con un solapamiento lateral y frontal de 80%, un tamaño de píxel promedio de 2,04 cm y por debajo del límite de almacenado según obturación del sensor. Todos los vuelos fueron realizados entre las 11:00 y las 12:00 horas.

Cuadro 4. Condiciones climáticas y propósito de cada vuelo durante las diferentes etapas fenológicas del sorgo, Cañas, Guanacaste, 2023.

Ciclo	Etapas fenológica	DDS	Uso imágenes	Promedio Temperatura °C	Promedio velocidad viento (km/h)
	-	0	MDT	30,2	6,4
Primer ciclo	Hoja bandera visible	42	Multiespectral+MDS	30,0	1,6
	Estado de bota	56	Multiespectral	31,9	8,0
	Floración	62	Multiespectral	32,1	12,9
	Grano lechoso	74	Multiespectral	34,5	11,3
	Grano pastoso	83	Multiespectral + MDS	31,0	12,9
Soca	Grano lechoso	183	Multiespectral+MDS	34,7	15,2
	Grano pastoso	193	MDS	34,6	21,1

Nota: Elaboración propia, 2024

Por otra parte, para lograr mayor eficacia en la adquisición de las imágenes, los vuelos se realizaron en condiciones de cielo despejado, con intensidades de luz moderada y radiación estable. Asimismo, se tomaron imágenes del panel de reflectancia (Figura 7) antes y después de cada vuelo para la calibración radiométrica de las imágenes.

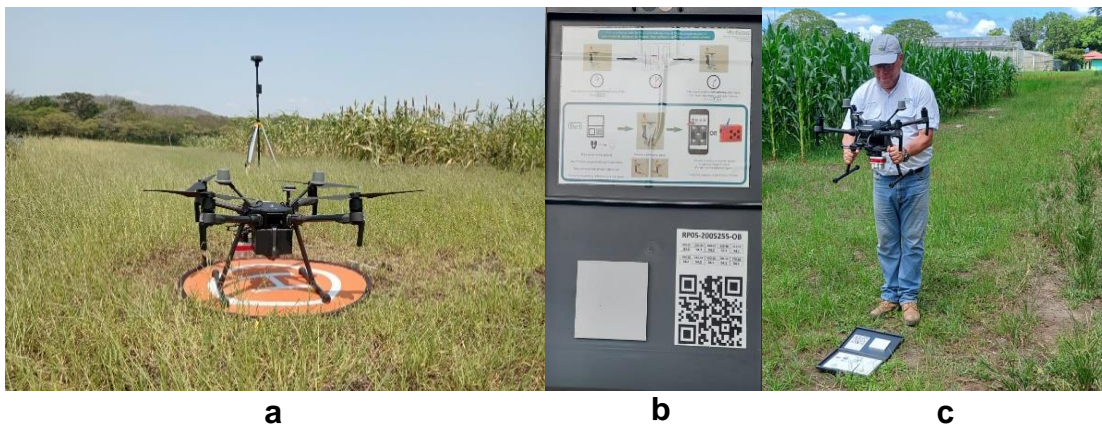


Figura 7. a: RPAS Matrice 210 con cámara AL05 y antena RTK; b: panel de reflectancia; c: ejemplo de toma de imágenes del panel de reflectancia, Cañas, Guanacaste, 2023.

3.7. Muestreo de campo

3.7.1. Altura de planta

En un área de dos metros lineales de los surcos centrales, se midió con una cinta métrica desde la base del tallo hasta el ápice de la hoja mayormente expuesta (Figura 8a) o extremo de la panoja (Figura 8b); para esto, se seleccionaron 8 plantas al azar dentro de las filas internas de la parcela. Esta medición se hizo en tres tiempos distintos, a los 42, 83 y a los 193 DDS.



Figura 8. Descripción de la medición de altura de planta de sorgo en campo. Panel a: hoja expuesta, panel b: panoja, Cañas, Guanacaste, 2023.

3.7.2. Rendimiento de materia seca (MS) de forraje

La parcela o unidad experimental se dividió en dos partes iguales denominadas (subparcelas). La cosecha de forraje se realizó entre los 85-90 DDS. Se cortaron todas las plantas a nivel de suelo dentro de un metro lineal de los dos surcos centrales de la primera subparcela. Luego, se utilizó una balanza granataria para cuantificar la materia fresca total en gramos. Se tomó una muestra de aproximadamente 500 g y se colocaron en bolsas de papel identificadas. Posteriormente, las muestras se secaron en una estufa con circulación forzada de aire a 60 °C durante 72 horas. Una porción de muestra seca a 60°C, se sometió a 105°C en una estufa, con el fin de estimar el porcentaje de materia seca total (Cuadro 5).

3.7.3. Rendimiento de grano

La cosecha de grano se realizó entre los 115-120 DDS. Esta variable se calculó mediante el muestreo de las panojas en estado de madurez fisiológica en dos metros lineales de los surcos centrales de la segunda subparcela, las panojas se secaron al sol, se trillaron y se pesaron los granos secos con el uso de una balanza electrónica marca Ocony SS.

Durante los muestreos tanto de forraje como de grano, se descartaron los surcos externos de la parcela para evitar el efecto borde. Los resultados del rendimiento se expresaron en términos de kilogramos de materia seca de forraje y kg de grano por hectárea. Todas las muestras fueron analizadas en el Laboratorio de Nutrición Animal del INTA.

Cuadro 5. Fórmulas para el cálculo de variables de rendimiento en sorgo, Cañas, Guanacaste, 2023.

Variable	Fórmula
Materia seca a 60°C	$\frac{\text{Peso final muestra seca}}{\text{Peso muestra fresca}} * 100$
Materia seca a 105°C	$\frac{\text{Peso final muestra seca a } 105^{\circ}\text{C}}{\text{Peso muestra seca a } 60^{\circ}\text{C}} * 100$
Materia seca total	$\frac{\%MS60 * \%MS105}{100}$
Rendimiento de MS (t.ha ⁻¹)	$\frac{t \text{ MF/ha} * \%MS_{total}}{100}$

Nota: Elaboración propia, 2023; MF: materia fresca; MS: materia seca

3.8. Proceso fotogramétrico

Se utilizó el software PIX4Dmapper, versión 4.7.5 (Pix4D, S.A., Lausanne, Switzerland) para realizar todo el proceso fotogramétrico. Todas las imágenes fueron cargadas al software y se implementó el flujo de trabajo para levantamientos multiespectrales. Primero, se ejecutó el paso inicial de identificación de puntos clave coincidentes, localización, orientación y optimización de la cámara (PIX4D, 2017).

3.8.2. Nube de puntos densa y malla

Se ejecutó el segundo paso donde se crean puntos de ajuste automáticos que resultan en una reconstrucción georreferenciada en forma de nube de puntos densa (Figura 10a). Luego, con base en la nube de puntos se generó una malla con textura 3D (Figura 10b) que representa el área de vuelo y los objetos de estudio (suelo, vegetación, edificios, cuerpos de agua, etc).

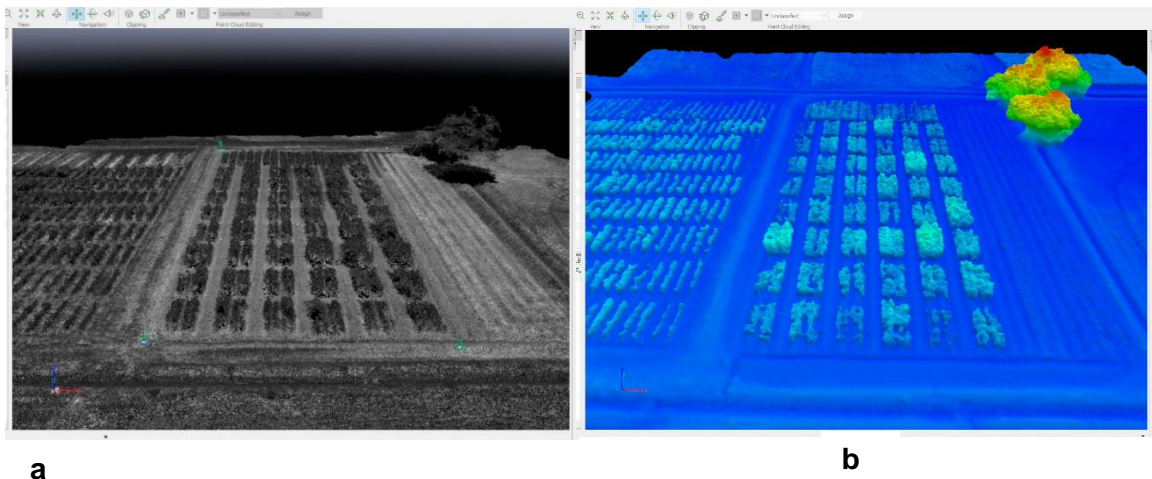


Figura 10. Construcción de nube de puntos densa y malla del sitio experimental, Cañas, Guanacaste, 2023.

3.8.3. Calibración radiométrica

Para el proceso de calibración radiométrica en PIX4Dmapper se eligió la opción de calibración (sólo cámara) y las imágenes del panel fueron automáticamente reconocidas por el software (Figura 11). Para asegurar una adecuada calibración, se revisó que los datos de reflectancia proporcionados por Micasense estuvieran correctos en cada banda espectral.

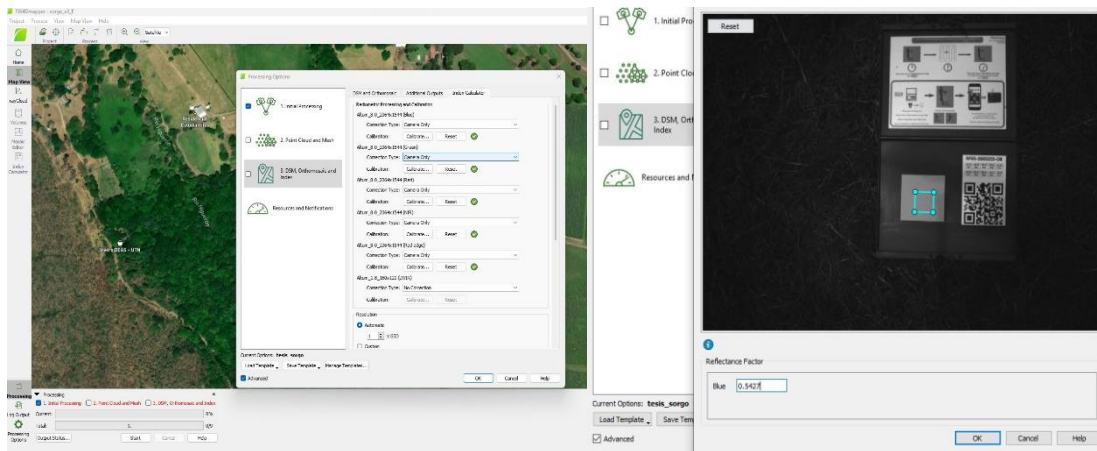


Figura 11. Proceso de calibración radiométrica de las imágenes multispectrales.

En este sentido, la fórmula para calcular la radiancia espectral a partir de los valores de píxeles de las imágenes del panel se muestra en la ecuación 1.

$$L = V(x, y) * \frac{a1}{g} * \frac{p - pBL}{te + a2y - a3tey} \quad (1)$$

Donde:

p , es el valor de píxel normalizado

pBL , es el valor de nivel negro normalizado

$a1$, $a2$, $a3$ son los coeficientes de calibración radiométrica

$V(x, y)$, es la función polinómica para la ubicación de píxeles (x, y) .

te : es el tiempo de exposición de la imagen

g : es el ajuste de ganancia del sensor

x, y : son las columnas de píxeles y el número de filas, respectivamente

L : es la radiancia espectral en $W/m^2/sr/nm$

Para convertir los valores de radiancia espectral a reflectancia el software utilizó las imágenes del panel de calibración radiométrica. Los datos de calibración del panel se proporcionan como reflectancia absoluta, entre 0 a 1 en el rango de 400 nm a 850 nm (Micasense, 2023). La función de transferencia de radiancia a reflectancia se muestra en la ecuación 2.

$$F_i = \frac{\rho_i}{avg(L_i)} \quad (2)$$

Donde:

F_i es el factor de calibración de la reflectancia en cada banda espectral.

ρ_i : es la reflectancia promedio del panel de calibración para la i -ésima banda (a partir de los datos de calibración del panel proporcionados por MicaSense).

$avg(L_i)$ es el valor promedio de la radiancia de los píxeles dentro del panel para cada banda.

3.8.4. Generación del MDT, MDS y ortomosaico

Sobre la base del modelo 3D creado previamente, se generaron tres productos el MDT, MDS y ortomosaico. Estos productos se seleccionaron en el paso tres del flujo de procesamiento. En el caso del MDS se utilizó la interpolación de distancia inversa ponderada que el software trae por defecto y que es recomendada para mediciones de altura variables (PIX4D, 2017). Además, la resolución del DTM se ajustó a lo recomendado por PIX4Dmapper, es decir cinco veces el GSD final, con lo anterior se lograron mejores reconstrucciones del modelo.

Las resoluciones espaciales se definieron cuando los productos (ortofotos y modelos) se exportaron para garantizar que los productos de diferentes vuelos tuvieran una resolución similar. Un ejemplo de la primera página del reporte con

los parámetros de calidad adecuados del procesamiento se adjunta en el anexo 3.

3.9. Cálculo de índices espectrales

Este paso se ejecutó con la calculadora de PIX4D mapper al final del procesamiento. Se realizó una revisión de bibliografía para la elección de índices que hubiesen tenido buenos resultados en otras investigaciones para la predicción de biomasa o rendimiento de grano en cultivos anuales. Asimismo, se analizó la relación de las bandas espectrales con el rendimiento del cultivo en general.

Cuadro 6. Índices de vegetación utilizados en la investigación, Cañas, Guanacaste, 2023.

Abreviatura	Nombre	Fórmula	Referencia
BCC	Índice de Coordinada cromática azul	$B/(R + G + B)$	(De Swaef et al., 2021)
CARI	Relación borde rojo	RE/R	(Ballester et al., 2019)
CIRE	Índice de clorofila de borde rojo	$(NIR/RE) - 1$	(Wan et al., 2020)
CVI	Índice de vegetación de clorofila	$NIR(R/G2)$	(Peroni Venancio et al., 2020)
DVI	Índice de diferencia de vegetación	$NIR - R$	(G. Yang et al., 2017)
GCI	Índice de clorofila verde	$(NIR/G) - 1$	(Mandal et al., 2022)
GLI	Índice de verdor de hojas	$(2G - R - B) / (2G + R + B)$	(Lussem et al., 2018)
GNDVI	Índice de diferencia normalizada de vegetación verde	$(NIR - G) / (NIR + G)$	(Ranjan et al., 2019)

IKAW	Índice de Kawashima	$(R-B) / (R+B)$	(Kawashima & Nakatani, 1998)
NDRE	Índice de diferencia normalizada de borde rojo	$(NIR - RE) / (NIR + RE)$	(Marques Ramos et al., 2020)
NDVI	Índice de diferencia normalizada de vegetación	$(NIR - R) / (NIR + R)$	(Marques Ramos et al., 2020)
RCC	Índice de Coordenada cromática roja	$R / (R + G + B)$	(De Swaef et al., 2021)
RDVI	Índice de vegetación de diferencia renormalizada	$NIR - R / \sqrt{NIR}$ $+ R$	(Ranjan et al., 2019)
REDVI	Red Edge DVI	NIR-RE	(Kanke et al., 2016)
RGRI	Índice de relación rojo-verde	R/G	(Tayade et al., 2022)
SAVI	Índice de vegetación ajustado al suelo	$1.5(NIR - R) / (NIR + R + 0.5)$	(da Silva et al., 2020)
SR	Simple ratio	NIR / R	(Serrano et al., 2000) (Ranjan et al., 2019)

Nota: Elaboración propia, 2024

3.10. Construcción de vectores y segmentación de suelo

Los polígonos con el tamaño de la parcela o subparcela se definieron y se ubicaron correctamente (georreferenciación) previo a la extracción de los datos correspondientes a cada área presente en el ensayo. Además, se realizó una segmentación de suelo, con base en el procedimiento propuesto por (Matias et al. (2020), mediante un código en software R con el paquete FieldimageR y FieldimageR.Extra. Un resumen del procedimiento se muestra en la figura 12 y el código se puede acceder mediante el repositorio de github (<https://github.com/OpenDroneMap/FIELDimageR?tab=readme-ov-file#p3>).

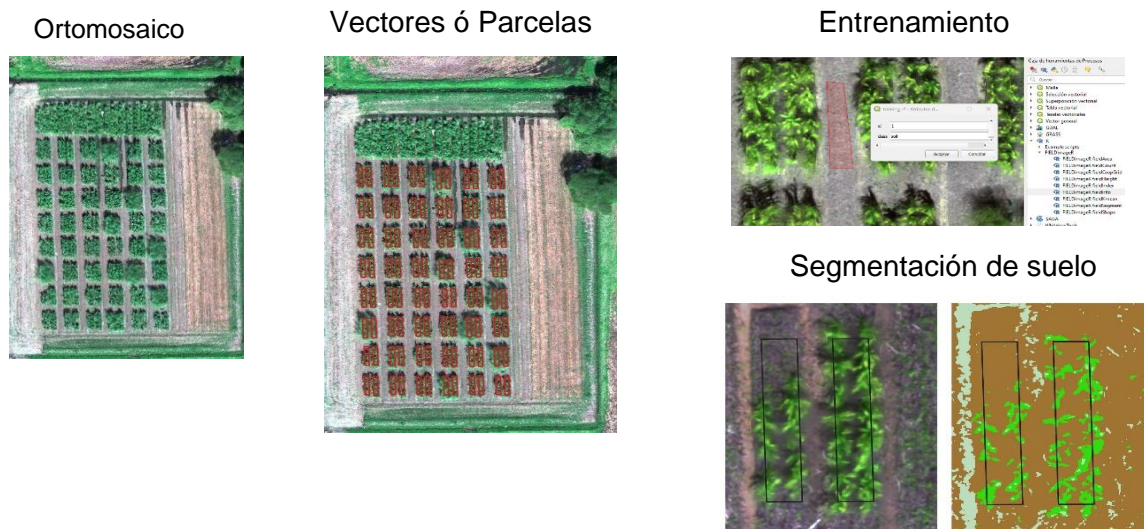


Figura 12. Resumen del flujo de trabajo para la segmentación de suelo. Algoritmo de clasificación Random Forest, Cañas, Guanacaste 2023.

Este proceso de dibujo y segmentación de suelo se realizó para cada vuelo. Posteriormente se vectorizó el raster clasificado y se seleccionaron los polígonos finales de las parcelas con base en los valores referentes únicamente a la vegetación del cultivo (exclusión de suelo u otros rasgos presentes en el área). Es importante indicar que durante la delimitación se realizó un ligero buffer para capturar los píxeles de las hileras centrales.

3.11. Extracción de datos del MDS-MDT

Con los vectores de las parcelas segmentadas por suelo, se extrajeron los valores promedio de los píxeles del modelo digital de terreno (vuelo 0 DDS) y modelos digitales de superficie (vuelos 83 y 193 DDS) mediante la herramienta de estadística zonal del software QGIS versión 3.34.9 (QGIS Development Team, 2024). Las capas resultantes se combinaron en una sola mediante el ID único de

la parcela. Posteriormente se asociaron los datos reales tomados en campo, con los datos estimados por el proceso fotogramétrico.

3.12. Extracción de datos multiespectrales para cada vuelo

Para el caso de los datos multiespectrales y al tener 17 ortomosaicos correspondientes a los índices o bandas (Cuadro 6) se implementó un script con el lenguaje de programación R (R Core Team, 2020) para extraer los valores promedios de cada mosaico por subparcela. Un ejemplo del script implementado en R se adjunta en anexo 4. Posteriormente, los datos multiespectrales fueron unidos a la hoja electrónica de laboratorio (biomasa y grano) mediante el código de parcela establecido.

3.13. Predicción de la altura de planta

Como se mencionó anteriormente un MDT genera la elevación de la superficie del suelo, y un MDS es la suma del MDT y la superficie de vegetación expuesta. Por lo tanto, la predicción de la altura de las plantas se obtuvo mediante la ecuación 3.

$$Altura (plantas) = Altura(MDS) - Altura (MDT) \quad (3)$$

3.14. Asociación entre altura real de planta y estimada por el proceso fotogramétrico

Se realizaron análisis de correlación y de regresión lineal entre la altura real de planta y los datos estimados por el proceso fotogramétrico. Los análisis se realizaron por etapa fenológica, tanto para el primer ciclo de cosecha y el segundo (soca) así como un análisis de los datos unidos referentes al final de cada ciclo.

3.15. Asociación entre los datos de rendimiento de biomasa y grano con los índices espectrales

Se realizaron correlaciones multitemporales, es decir entre los índices espectrales de cada etapa fenológica en que se realizaron los vuelos y los datos de rendimiento de biomasa y grano. Es importante indicar que solo se realizó un vuelo durante el ciclo de soca, y el mismo fue en la etapa de grano lechoso; lo anterior por complicaciones de viento durante la época del desarrollo del cultivo.

3.16. Modelos de predicción de biomasa y grano

La construcción de modelos de predicción de biomasa y grano se realizaron con base en los índices de vegetación que tuvieron correlaciones superiores a 0,50. Se utilizó el modelo de regresión Random Forest (RF). Los datos fueron particionados en una proporción 70/30 para el proceso de entrenamiento y validación respectivamente. Los modelos se realizaron con el uso del paquete regressoR desarrollado por Rodríguez (2023) mediante el software R (R Core Team, 2020). Además, para evaluar el desempeño de los modelos se utilizaron los indicadores estadísticos, R^2 y RMSE y la correlación entre los datos observados y la predicción. Estos parámetros son arrojados por el software en la salida del modelo. Las fórmulas se muestran en las siguientes ecuaciones.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad 4$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad 5$$

Donde n es el número de muestras del modelo; y_i es el valor medido realmente; \bar{y}_i es el valor medio del valor medido; \hat{y}_i representa el valor estimado.

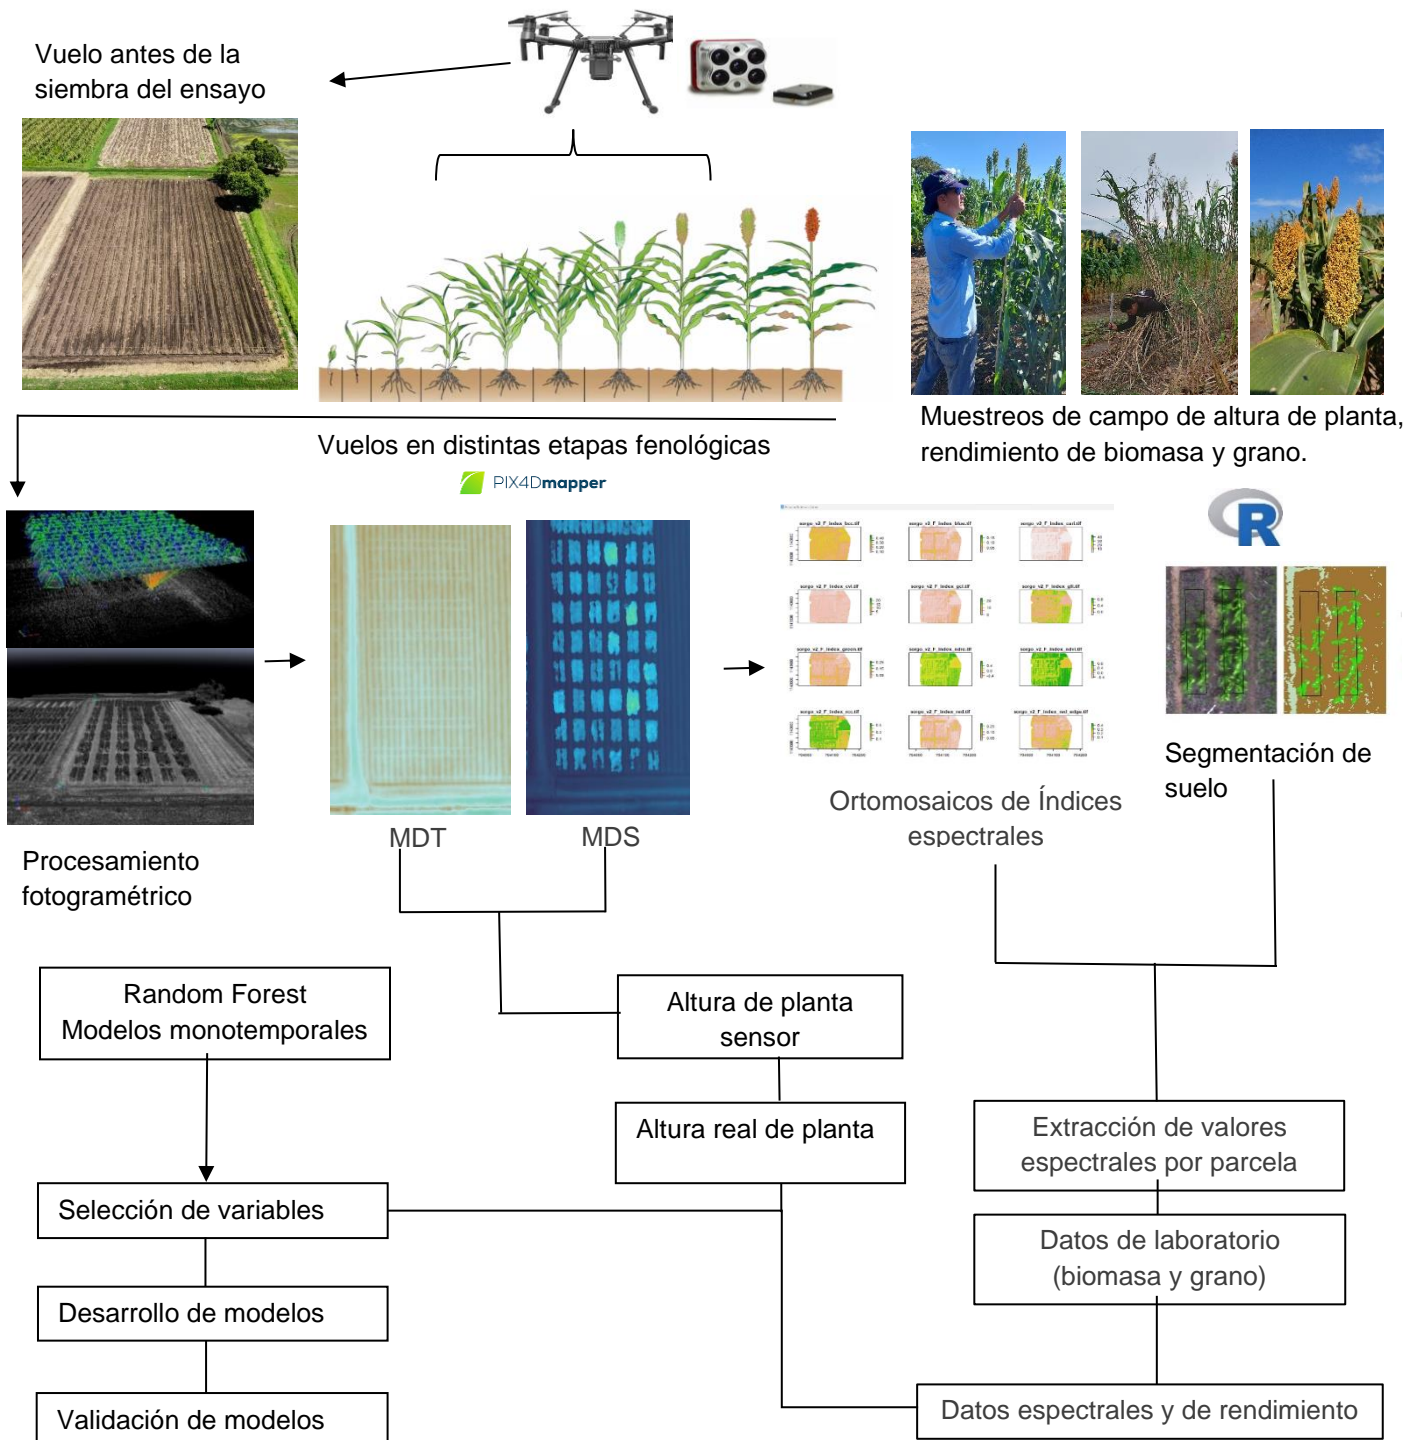


Figura 13. Resumen metodológico de la investigación.

Capítulo 4. Resultados y discusión

4.1. Predicción de altura de planta

Los datos de altura de planta medidos en campo a los 42 DDS oscilaron entre 0,20 y 1,06 m (media=0,55 y EE=0,03 m), Figura 14. Adicionalmente, las mediciones al final de los ciclos de cultivo fueron muy similares; para los 83 DDS osciló entre 1,32 y 2,54 (media 1,83 y EE=0,04 m) y para los 193 DDS entre 1,19 y 2,28 (media 1,66 y EE=0,04 m).




Figura 14. Box plot de altura de planta según días después de la siembra, Cañas, Guanacaste, 2023.

Por otra parte, la figura 15 muestra la relación lineal entre la altura de planta medida manualmente y la derivada por el sensor en distintas etapas de crecimiento representados con diferentes colores. Los resultados mostraron una fuerte correlación ($r = 0,76, 0,87$ y $0,91$) a los 42, 83 y 193 DDS respectivamente y con los datos de todas las etapas en conjunto mostró una correlación de $0,91$.

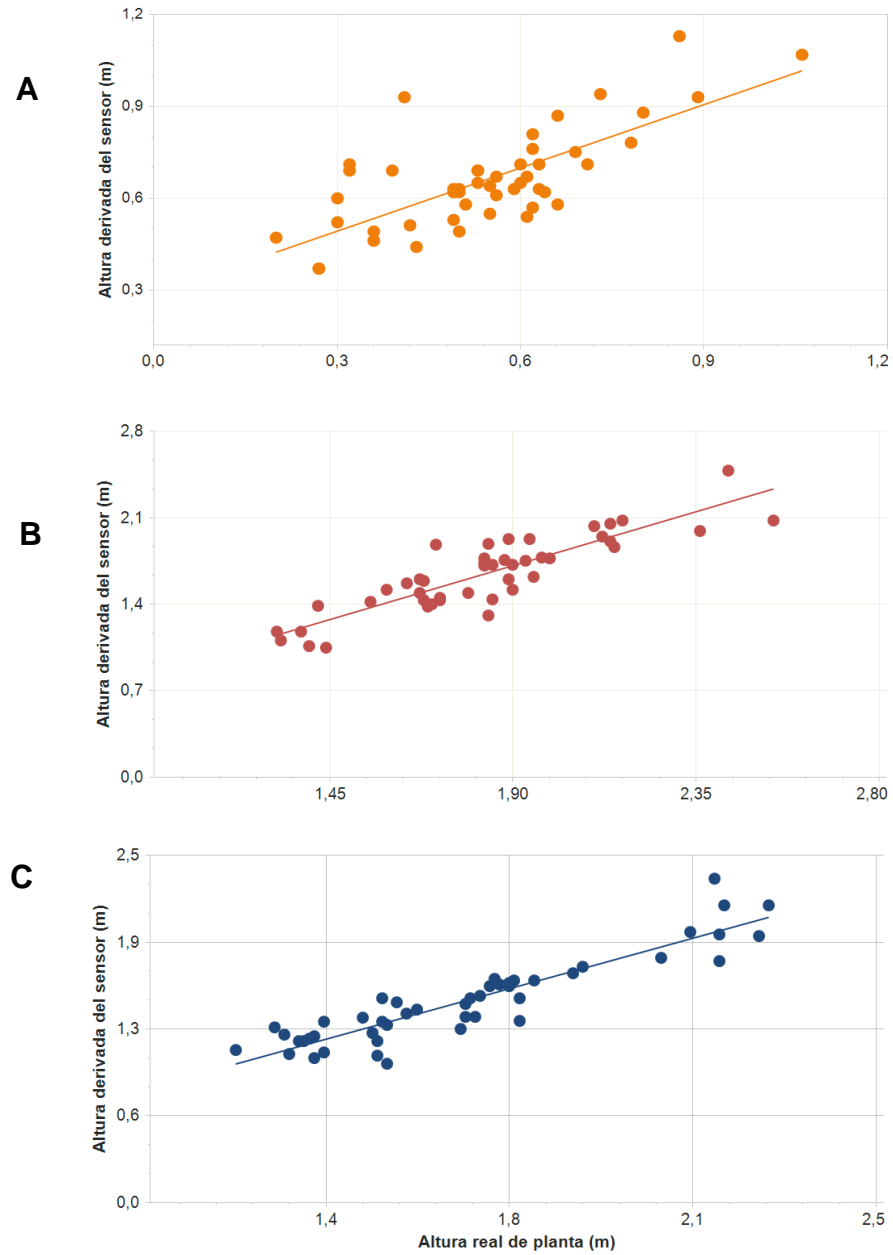


Figura 15. Correlaciones de altura de planta medida manualmente y altura derivada del sensor según días después de la siembra; Panel A: 42 DDS, Panel B: 83 DDS, Panel C: 193 DDS, Cañas, Guanacaste, 2023.

La correlación entre la altura de planta medida y estimada por el sensor a los 42 DDS fue más bajo, con un R^2 de 0,50, RMSE 0,13 m, mientras que a los 83 y 193 DDS se obtuvo un R^2 de 0,86, RMSE 0,13 m y un R^2 0,84 RMSE=0,12 m respectivamente. Asimismo, en las etapas donde normalmente se realizan las mediciones de altura de planta del cultivo (final del ciclo) los datos mostraron un ajuste similar, Figura 16.

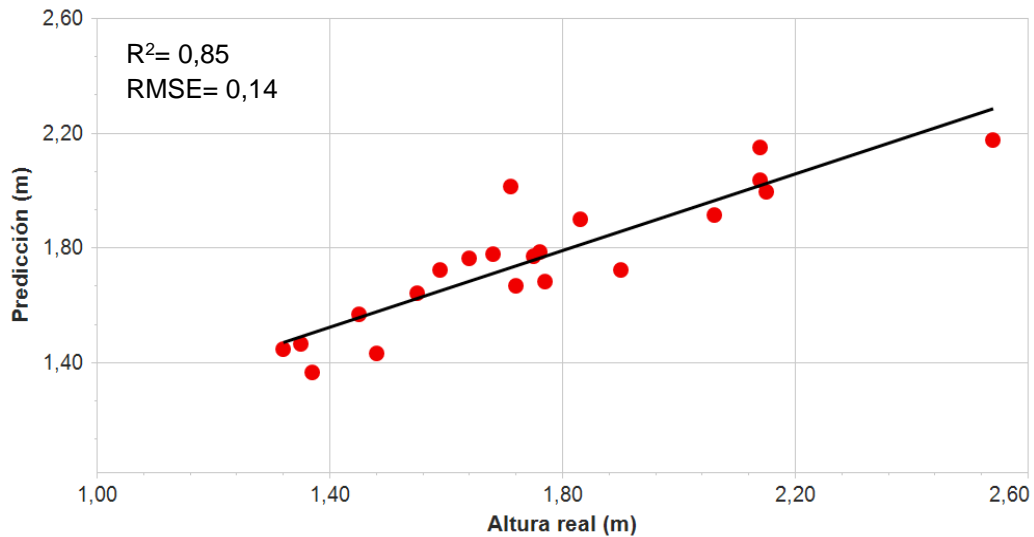


Figura 16. Valores reales y predicciones de altura de planta para el primer ciclo del cultivo y soca, Cañas, Guanacaste, 2023.

Los resultados de esta investigación concuerdan con los obtenidos por Malambo et al. (2018) en el cultivo de sorgo, quienes obtuvieron correlaciones superiores a 0,80 entre la altura medida manualmente y la derivada por sensores acoplados en RPAS. Asimismo, Shu et al. (2023) también obtuvo una fuerte correlación cuando realizó la combinación de las etapas de crecimiento, pero mostró un mayor error de estimación de la altura de la planta a medida que el cultivo avanzaba en sus etapas de crecimiento; lo anterior explicado por los errores en la elaboración del MDT a medida que incrementaba la cobertura del cultivo, pero en esta investigación no sucedió debido a que el MDT fue generado previo al establecimiento del cultivo.

La altura de planta medida durante las primeras etapas de crecimiento puede generar información acerca del crecimiento normal de los cultivares según la respuesta a eventos ambientales. Una menor correlación entre la altura manual y derivada del sensor a los 42 DDS puede ser explicada debido a la incorporación de datos de suelo al MDS durante el proceso de segmentación y posterior extracción de los píxeles por parcela, lo que resulta en sobreestimaciones o subestimaciones de la elevación del dosel del cultivo (Hassan et al., 2019).

La precisión de la predicción de la altura de planta alcanzada en esta investigación fue bastante alta (RMSE = 0,14 m), respaldada por un error muy bajo al utilizar GCP y un MDT previo al establecimiento del cultivo. Es decir, normalmente se espera que los errores geométricos sean de pocos centímetros ya que la precisión del procesamiento con los GCP utilizados en este estudio fue menor a 3 cm en los vuelos (Anexo 2,3). Sin embargo, este error podría ser mejorado para aplicar esta tecnología en cualquier etapa de crecimiento del cultivo.

El error encontrado en la predicción de la altura de la planta pudo deberse a dos motivos. El primero, al movimiento de la parte superior del material de sorgo por efecto del viento que es conocido como un factor crítico para obtener imágenes de alta calidad ya que disminuye la identificación de puntos coincidentes entre imágenes en el procesamiento (Mesas-Carrascosa et al., 2015). El segundo, y más probable para el caso de este estudio debido a la buena precisión al utilizar GCP, es la diferencia en el ángulo de las hojas y la estructura del dosel entre los materiales muestreados manualmente que influye en la diferencia con las mediciones derivadas por el sensor (Li et al., 2018).

4.2. Rendimiento de biomasa seca

El rendimiento de biomasa seca para el primer ciclo de cultivo osciló entre 5,65 a 20,36 t.ha⁻¹, con una media de 9,97 t.ha⁻¹ y un coeficiente de variación (CV) del 27% (Figura 17). El 5% de los datos superaron las 13,66 t.ha⁻¹ que correspondió a los rendimientos del material Sorgo Negro. Para el ciclo de soca (193 DDS) los rendimientos oscilaron entre 3,43 y 14,80 t.ha⁻¹, una media de 8,14 t.ha⁻¹ donde los materiales PCR-3-22 y CENTA-CF tuvieron coeficientes de variación de 29 y 40% respectivamente, mientras que para los materiales de sorgo BMR-09-36, CENTA RCY, Sorgo Negro y Sureño los CV fueron de 26, 14, 24 y 27 % respectivamente.

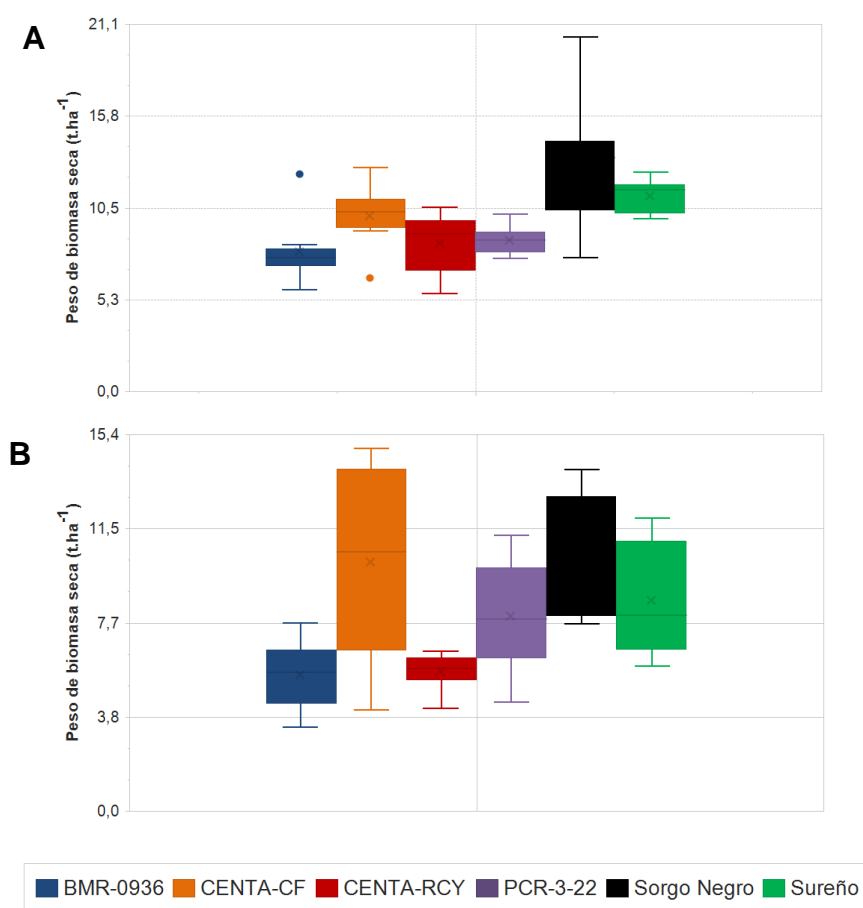


Figura 17. Box plot de rendimiento de biomasa seca según ciclo de cultivo y genotipo; Panel A: Primer ciclo, Panel B: Soca, Cañas, Guanacaste, 2023.

4.2.1. Correlación temporal de índices o bandas espectrales y rendimiento de biomasa seca

El análisis de correlación entre los rendimientos de biomasa y los índices de vegetación o bandas espectrales individuales según etapa fenológica para el primer ciclo de cultivo se muestran en el cuadro 7. Varios índices mostraron una correlación superior a 0,50 en la etapa fenológica de estado de bota y floración, donde destacaron IKAW, NDRE y CIRE ($r=0,70-0,59$ y $0,58$ respectivamente). Sin embargo, los valores de correlación decrecieron en las etapas de grano lechoso y pastoso, inclusive en ésta última etapa, la mayoría de correlaciones no fueron significativas.

Cuadro 7. Correlación de Spearman entre bandas e índices espectrales y el rendimiento de biomasa seca para el primer ciclo de cultivo, Cañas, Guanacaste, 2023.

ÍNDICE O BANDA	Etapa fenológica (primer ciclo)				
	Hoja Bandera visible	Estado de bota	Floración	Grano lechoso	Grano pastoso
BCC	0,43**	0,53**	0,40**	0,31*	0,31*
BLUE	0,08	0,34*	0,17	-0,39**	-0,24
CARI	0,06	-0,01	0,08	0,32*	0,14
CIRE	0,45**	0,58**	0,58**	0,38**	0,26
CVI	0,47*	0,52**	0,47**	0,20	0,27
DVI	0,20	0,46**	0,29	0,22	0,16
GCI	0,49**	0,56**	0,54**	0,42**	0,32*
GLI	-0,16	-0,17	0,02	0,21	0,07
GNDVI	0,51**	0,57**	0,56**	0,46**	0,38**
GREEN	-0,03	-0,14	-0,01	-0,27	-0,23
IKAW	-0,38**	-0,70**	-0,55**	-0,45**	-0,24
NDRE	0,45**	0,59**	0,58**	0,43**	0,28
NDVI	0,36*	0,43**	0,45**	0,43**	0,25
NIR	0,19	0,47**	0,25	0,19	0,14
RCC	0,01	-0,06	-0,32*	-0,32*	-0,12
RDVI	0,22	0,47**	0,33*	0,26	0,21

RED_EDGE	-0,02	-0,14	0,01	-0,26	-0,15
RED	-0,01	-0,18	-0,05	-0,56**	-0,32*
REDVI	0,24	0,51**	0,36*	0,22	0,17
RGRI	0,08	0,03	-0,23	-0,31*	-0,14
SAVI	0,24	0,47**	0,32*	0,26	0,22
SR	0,33**	0,38**	0,38**	0,29	0,22

Nota: Elaboración propia, 2024; * $p < 0,05$; ** $p < 0,01$

Para el ciclo de soca, los vuelos de las etapas de hoja bandera y estado de bota no pudieron realizarse por el fuerte viento de la zona, y únicamente pudieron obtenerse las imágenes en la etapa de grano lechoso. Los resultados de correlación entre el rendimiento de biomasa seca y los índices o bandas espectrales fueron muy similares al primer ciclo de cultivo (Figura 18). En esta etapa destacaron los índices o bandas BLUE, GNDVI, DVI y GCI, pero al igual que el primer ciclo de cultivo fueron iguales o inferiores a 0,50.




Figura 18. Matriz de correlación de spearman entre índices o bandas espectrales en etapa de grano lechoso y el rendimiento de biomasa seca para el ciclo de soca; PS: Peso seco de biomasa, Cañas, Guanacaste, 2023.

Por otra parte, aunque en las etapas del final del ciclo de cultivo, la mayoría de correlaciones no fueron significativas entre índices o bandas espectrales y el rendimiento de biomasa, si hubo una correlación significativa entre altura derivada del sensor y el rendimiento de biomasa seca al final del primer ciclo ($r=0,61$) y la soca ($r=0,68$). Para el caso del rendimiento de grano, no hubo correlación con la altura de planta (Figura 19). Lo anterior sugiere que la altura de planta es un atributo que podría incluirse en conjunto con los índices de vegetación de mayor correlación de otras etapas fenológicas para modelos de predicción de biomasa de sorgo.

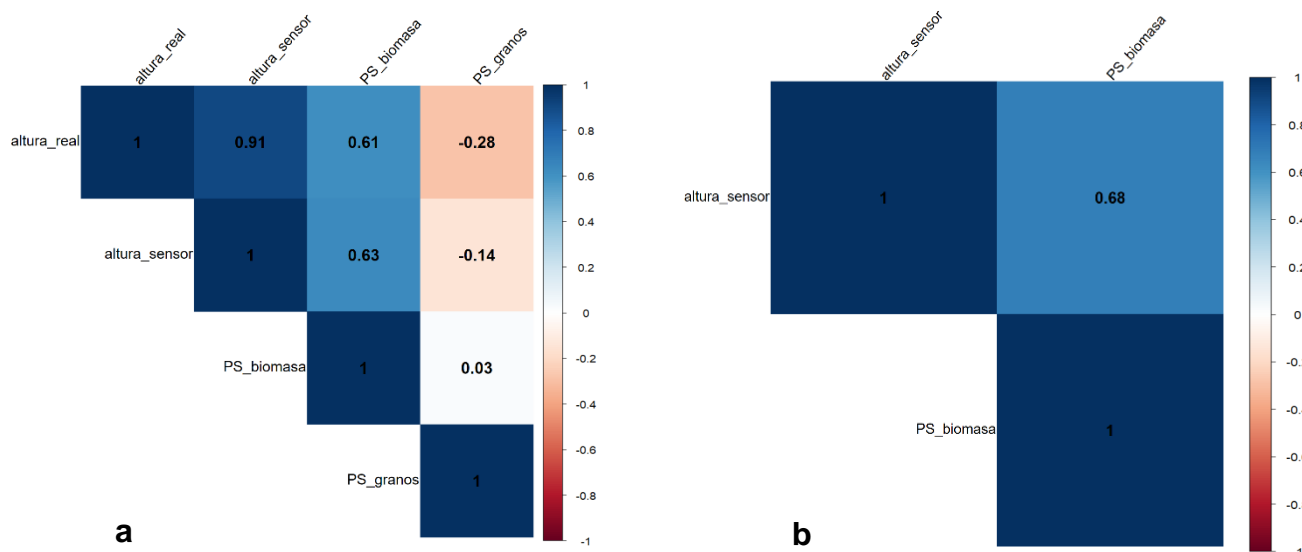


Figura 19. Correlación entre altura de planta derivada del sensor y el rendimiento de biomasa y grano; Panel a: primer ciclo de cultivo; Panel b: soca; PS: Peso seco, Cañas, Guanacaste, 2023.

4.2.2. Modelos de predicción de rendimiento de biomasa seca

Con los resultados de correlación temporal obtenidos en la sección anterior, se condujeron análisis de regresión con el modelo Random Forest para detectar la etapa que estima con mayor precisión los rendimientos de biomasa seca. Los valores de correlación de la predicción al utilizar datos temporales oscilaron entre 0,42 a 0,75 y los valores de RMSE oscilaron entre 1,40 a 2,20 t.ha⁻¹ (Cuadro 8).

Cuadro 8. Modelos de predicción de biomasa seca de sorgo según etapa fenológica, Cañas, Guanacaste, 2023.

MODELO	DDS	ETAPA FENOLÓGICA	VARIABLES	CORRELACIÓN	RMSE
1	56	Estado de bota	Sólo IV	0,60	1,70
2			IV +altura sensor	0,75	1,40
3	62	Floración	Sólo IV	0,49	2,20
4			IV +altura sensor	0,63	1,60
5	74	Grano lechoso	Sólo IV	0,42	1,60
6			IV +altura sensor	0,62	1,50
7	183	Grano lechoso	Sólo IV	0,53	1,70
8			IV +altura sensor	0,63	1,80

Nota: Elaboración propia, 2024; DDS: días después de la siembra; IV: índices de vegetación

Se identificó que el estado de bota, es la mejor etapa fenológica para la predicción del rendimiento de biomasa (cuadro 8). Además, al incluir el valor de altura de planta derivada del sensor como variable regresora con los índices de vegetación, el modelo reduce el error en 0,30 t.ha⁻¹ y aumenta la correlación a 0,75.

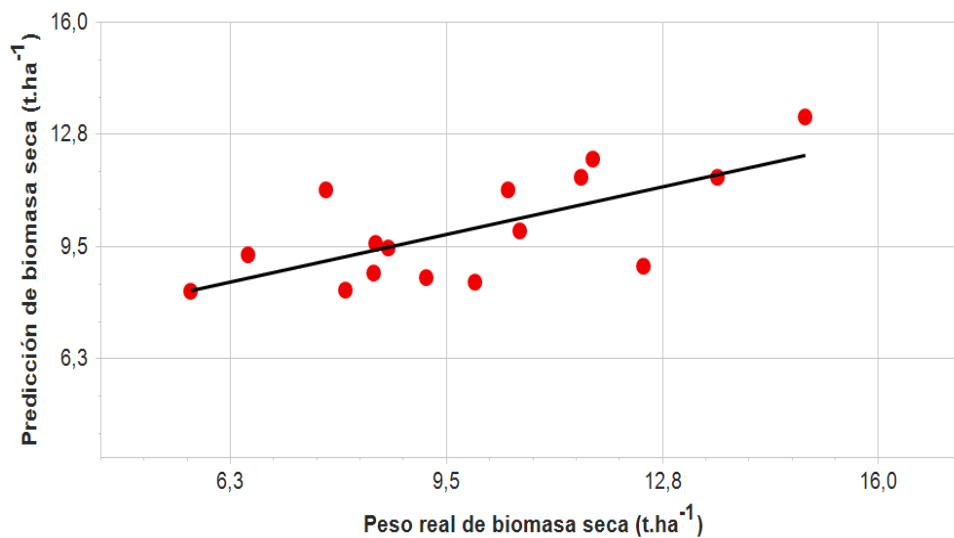


Figura 20. Predicción de biomasa seca con el algoritmo Random Forest incluyendo los índices espectrales y la altura del cultivo, Cañas, Guanacaste.

Por otra parte, el análisis de la importancia de las variables se centró en el modelo 2, donde se incluyeron los índices de vegetación y la altura del sensor para las predicciones de biomasa seca al final del primer ciclo. La altura del cultivo derivada por el sensor fue más influyente en las predicciones de biomasa que las características espectrales (Figura 21). Los índices de vegetación más importantes según el porcentaje de incremento del error cuadrático medio fueron IKAW, NDRE y BCC.

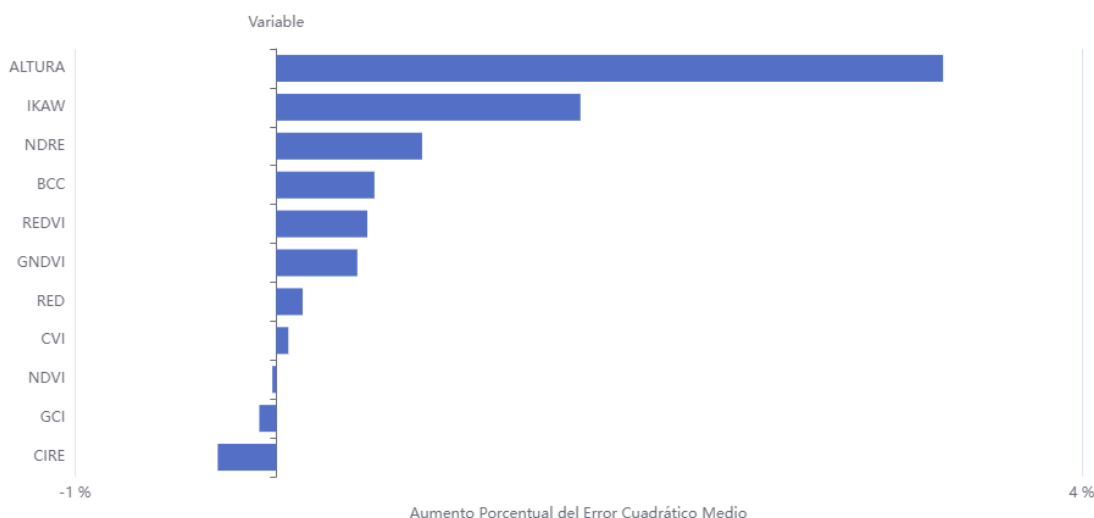


Figura 21. Importancia de variables en el modelo 2 sobre las predicciones de biomasa seca al final del primer ciclo de cultivo, Cañas, Guanacaste, 2023.

Los valores de reflectancia espectral se han reconocido relevantes en la predicción de la biomasa en diversos cultivos anuales como trigo y arroz (Jiang et al., 2019; Yue et al., 2017). No obstante, en este estudio la integración de la altura del cultivo junto con los valores de reflectancia incrementó significativamente la precisión del modelo para las diferentes etapas fenológicas. Resultados similares encontró Varela et al. (2021) en sorgo, donde la información geométrica fue uno de los predictores más importantes de la biomasa independientemente de la etapa fenológica.

Asimismo, Bendig et al. (2015) demostraron que el combinar la altura de la planta del cultivo de cebada derivada de modelos de superficie en conjunto con valores espectrales mejoraron la predicción de la biomasa. Este estudio destaca a los índices de vegetación que incluyan las bandas del rojo y borde rojo (IKAW-NDRE) como buenos predictores de biomasa. Lo anterior puede deberse a que estos índices son más sensibles a los cambios de senescencia del cultivo, por consiguiente, reflejar efectivamente las diferencias en la cobertura del dosel o las propiedades de las hojas.

Similar al NDVI, el NDRE es un buen indicador del contenido de nitrógeno de los cultivos (Fitzgerald et al., 2006); sin embargo, el reemplazo en el cálculo matemático de la banda roja por la banda del borde rojo hace que el NDRE sea más sensible al cambio de biomasa que el NDVI en las etapas del cultivo donde se alcanza el máximo desarrollo foliar; lo anterior se explica por una fuerte absorción de energía en la banda del borde rojo por efecto de la clorofila del cultivo. Es decir, una planta sana tiene más clorofila y absorbe más energía de luz en la banda del borde rojo, por lo que cuando la planta entra en senescencia su reflectancia en este espectro será mayor (Xie et al., 2018).

En el caso del IKAW, Bendig et al. (2014) mencionaron que con el uso de bandas en el espectro visible también se puede estimar la biomasa. Li et al. (2018) encontraron correlaciones moderadas (0,57) con biomasa seca al utilizar índices en el espectro visible (RGBVI). Con una mejora de estas predicciones, se podría reducir los costos al utilizar sensores que capturen bandas en el espectro visible los cuáles son más económicos que los sensores que incluyan otras bandas espectrales.

Por otra parte, se encontró una mejor predicción de la biomasa en la etapa fenológica de estado de bota. En esta etapa, el desarrollo la planta ha alcanzado su máxima superficie foliar y ha acumulado aproximadamente el 60% de su materia seca total (Gerik et al., 2003); similar a este estudio, en el cultivo de arroz Zheng et al. (2019) al utilizar índices de imágenes multiespectrales encontraron que la predicción de biomasa en la etapa previa a R3 fue significativamente mejor que en las etapas posteriores.

Asimismo, los resultados de este estudio relacionados a índices que involucran la banda de borde rojo también concuerdan con los hallazgos de Cheng et al. (2017) en arroz, quienes mencionaron que los IV basados en borde rojo están estrechamente relacionados con la predominancia de la biomasa de las hojas. Además, la mayoría de los IV seleccionados produjeron una menor precisión de predicción después de la etapa de floración debido al alto nivel de biomasa que

pueden saturar algunos índices, entre otros factores de interferencia como hojas y tallos distribuyendo asimilados al grano (Zheng et al., 2019).

4.3. Rendimiento de grano

El rendimiento de grano se midió únicamente para el primer ciclo. Los datos oscilaron entre 0,26 a 7,49 t.ha⁻¹, con una media de 3,26 t.ha⁻¹ y un coeficiente de variación del 58% (Figura 22). Solo los materiales CENTA-CF y el Sureño sobrepasaron las 4 t.ha⁻¹ en promedio.

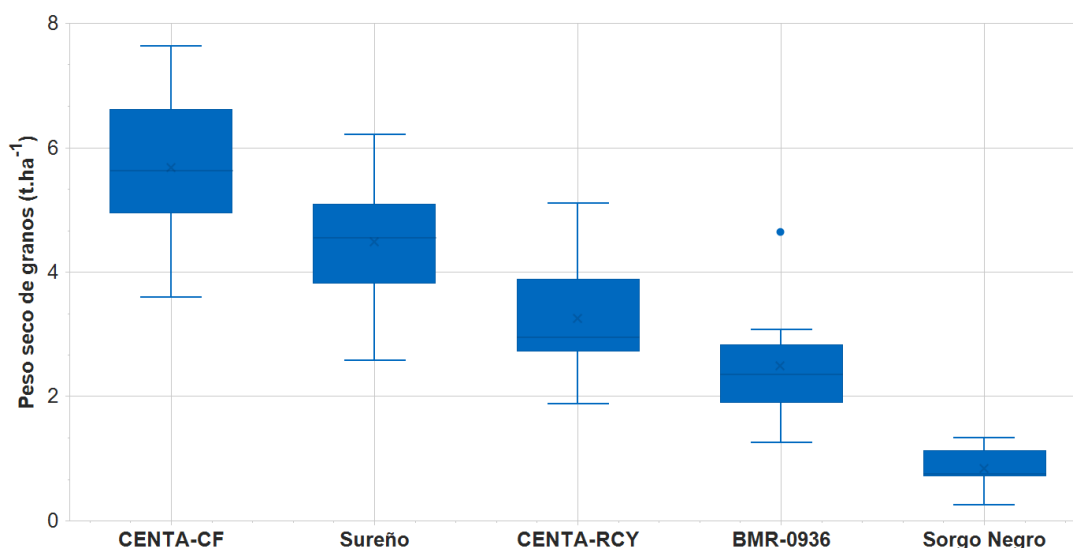


Figura 22. Box plot de rendimiento de grano seco según genotipo de sorgo, Cañas, Guanacaste, 2023.

4.3.1 Correlación temporal de índices espectrales y rendimiento de grano

El análisis de correlación entre los rendimientos de grano y los índices de vegetación o bandas espectrales individuales según etapa fenológica se muestran en el cuadro 9. Algunos índices mostraron correlaciones significativas superiores a 0,60 en estado de bota, pero no mantuvieron esta relación en la etapa de floración donde la panoja se encontraba completamente formada a excepción de los índices GLI y CARI. No obstante, la mayoría de índices

mostraron una correlación superior a 0,50 desde la etapa fenológica de grano lechoso, donde destacaron con mayores correlaciones en la etapa de grano pastoso los índices CIRE, NDRE, REDVI y la banda NIR ($r=0,70-0,68-0,72$ y $0,68$) respectivamente

Cuadro 9. Correlación de spearman entre bandas e índices de vegetación y el rendimiento de grano de sorgo, Cañas, Guanacaste, 2023.

Índice o Banda	Etapa fenológica				
	Hoja Bandera visible	Estado de bota	Floración	Grano lechoso	Grano pastoso
BCC	-0,42**	-0,35*	-0,42**	-0,22	0,22
BLUE	0,00	-0,18	-0,00	0,10	0,39*
CARI	0,51**	0,55**	0,37*	0,39*	0,39*
CIRE	0,05	0,14	0,05	0,60**	0,70**
CVI	-0,10	-0,36*	-0,22	0,07	0,085
DVI	0,18	0,37*	0,21	0,58**	0,67**
GCI	0,10	-0,03	0,05	0,50**	0,53**
GLI	0,49**	0,59**	0,47**	0,45**	0,45**
GNDVI	0,08	-0,05	0,00	0,44**	0,48**
GREEN	0,15	0,67**	0,22	0,33*	0,45**
IKAW	0,22	-0,05	0,16	-0,42**	-0,62**
NDRE	0,04	0,14	0,04	0,56**	0,68**
NDVI	0,18	0,34*	0,15	0,43**	0,53**
NIR	0,17	0,36*	0,21	0,59**	0,68**
RCC	-0,22	-0,63**	-0,17	-0,43**	-0,52**
RDVI	0,19	0,37*	0,23	0,54**	0,62**
RED_EDGE	0,12	0,46**	0,15	0,185	0,1553
RED	0,07	-0,25	0,05	-0,24	-0,29
REDVI	0,17	0,29	0,21	0,63**	0,72**
RGRI	-0,30	-0,63**	-0,21	-0,40*	-0,48**
SAVI	0,21	0,36*	0,21	0,54**	0,61**
SR	0,27	0,36*	0,26	0,59**	0,62**

Fuente: Elaboración propia, 2024; * $p < 0,05$; ** $p < 0,01$

4.3.2. Modelos de predicción de rendimiento de grano

Con los resultados de correlación temporal obtenidos en la sección anterior, se condujeron análisis de regresión con el modelo Random Forest para detectar la etapa que estima con mayor precisión los rendimientos de grano. Los valores de correlación al utilizar datos temporales oscilaron entre 0,70 y 0,85 y los valores de RMSE oscilaron entre 1,20 a 1,50 t.ha⁻¹ (Cuadro 10).

Cuadro 10. Modelos de predicción de grano de sorgo según etapa fenológica, Cañas, Guanacaste, 2023.

DDS	ETAPA FENOLÓGICA	CORRELACIÓN	RMSE
56	Estado de bota	0,70	1,50
74	Grano Lechoso	0,75	1,40
83	Grano Pastoso	0,85	1,20

Nota: Elaboración propia, 2024.

El análisis de la importancia de las variables para la predicción del rendimiento de grano se centró en el modelo estimado a los 83 DDS (Cuadro 10). Los índices de vegetación NDRE, CIRE y REDVI fueron más influyentes en las predicciones de grano según el porcentaje de incremento del error cuadrático medio (Figura 23).




Figura 23. Importancia de variables sobre las predicciones de rendimiento de grano mediante el modelo Random Forest, Cañas, Guanacaste, 2023.

En este estudio la etapa de grano pastoso produjo mejores predicciones que las etapas previas para el rendimiento de grano seco. Según Gerik et al. (2003), después de la floración hasta la madurez fisiológica, el desarrollo de la planta se centraliza en la formación del grano. Los asimilados almacenados en el tallo se translocan hacia el grano y la planta absorbe la última fracción de nutrientes. En la etapa de grano lechoso hay un aumento del peso del grano, sin embargo, en la etapa de grano pastoso se alcanza el 50% del peso final del grano; lo anterior podría explicar que esta etapa sea un buen momento para la predicción del rendimiento de grano seco.

En arroz, Lü et al. (2013) informaron que las etapas anteriores a la floración poseen una menor correlación con el rendimiento de grano. En maíz Yang et al. (2022), obtuvieron las mejores predicciones de grano en etapa de floración (grano lechoso) con un RMSE de 1,06 t.ha⁻¹ y en las etapas tardías obtuvieron menores predicciones. Los autores sugirieron que, en estas etapas de mayor madurez, el contenido de clorofila en las hojas disminuye, por lo que las relaciones entre la reflectancia del dosel y el rendimiento del grano pueden verse afectadas.

Los tres mejores índices para estimar el rendimiento de grano de sorgo en este estudio se componen de las bandas NIR y borde rojo; lo anterior es consistente con los resultados obtenidos por Marques Ramos et al. (2020) para el rendimiento de maíz al utilizar modelos de Random Forest con imágenes monotemporales; Los autores demostraron que al incluir el índice NDRE la correlación con el rendimiento de grano de maíz incrementó un 13%.

Asimismo, Saravia et al. (2022) reportaron que la mejor predicción para el rendimiento de maíz se logró con la combinación de los índices NDRE, CIRE y CCCl en la etapa de floración. En este sentido, los índices que se calculan al considerar la banda de borde rojo superan a otros índices para predecir los nutrientes en los cultivos. En adición, estos nutrientes están en su mayoría relacionados al potencial rendimiento de los cultivos (Ramoelo et al., 2015).

Conclusiones

La predicción de la altura de la planta basada en la extracción de valores promedio de píxeles de modelos digitales de terreno y de superficie logró altas correlaciones con las mediciones reales de campo principalmente en las etapas finales del cultivo.

En la etapa de crecimiento más temprano, los valores de altura de planta generados a partir de los modelos de terreno y de superficie tuvieron una correlación menor con los valores reales medidos en campo, que podrían atribuirse a la estructura del dosel entre los materiales muestreados manualmente que influye en la diferencia con las mediciones derivadas por el sensor

Se encontraron altas correlaciones del rendimiento de biomasa seca con índices de vegetación que utilizan la banda NIR y borde rojo, así como el índice IKAW que incluye bandas del espectro visible.

Se determinaron moderadas correlaciones entre la altura de planta y el rendimiento de biomasa, por lo que la inclusión de la altura de planta como variable regresora mejoró la predicción en todos los modelos; asimismo, se identificó que el estado de bota es la mejor etapa fenológica para la predicción de biomasa seca del cultivo de sorgo en el sitio de estudio.

El rendimiento de grano también correlacionó mayoritariamente con índices de vegetación que incluyeron bandas del infrarrojo y borde rojo. Además, se identificó que la etapa de grano pastoso es la más adecuada para la predicción del rendimiento de grano seco.

Recomendaciones

Es importante monitorear la estabilidad de los índices identificados en este estudio para la predicción del rendimiento de biomasa y grano del cultivo de sorgo mediante alta frecuencia de vuelos en una misma etapa fenológica.

Se deben realizar estudios con mediciones de altura de planta también al ápice de las hojas mayormente expuestas en etapas finales del cultivo con el propósito de explorar las diferencias con la altura de los modelos en comparación a la medición hasta el extremo de la panoja. Lo anterior sustentado en que una mayor cantidad de píxeles se encuentran sobre el ápice de las hojas en comparación con la cantidad de píxeles sobre las panojas, lo que afecta el valor medio extraído.

Se recomienda explorar otros modelos de aprendizaje automático, como soporte de máquinas vectoriales, K-vecinos más cercanos, árboles de decisión, así como la regresión penalizada Lasso o Ridge para comparar los resultados de las predicciones. Asimismo, se podrían incluir otras variables como humedad del suelo o número de hojas, que permitan mejorar la predicción del rendimiento de biomasa y grano del cultivo de sorgo.

En adición, se recomienda investigar la relación de datos multiespectrales con otros aspectos agronómicos como el estado nutricional del cultivo, riesgo de floración, detección de estrés o tolerancia a condiciones climáticas, así como la detección temprana de enfermedades, entre otros.

Asimismo, es importante investigar el uso de Lidar y otras tecnologías para la estimación de variables estructurales para el fenotipado de alto rendimiento. El uso del Lidar podría reconstruir variables estructurales de la planta con mucha más precisión lo que facilitaría el fenotipado en campo en el cultivo de sorgo.

Se recomienda realizar investigaciones en las épocas de menor velocidad de viento en la zona de estudio. Además, probar la tecnología en diferentes localidades climáticas y en distintos genotipos de sorgo que permitan detectar la estabilidad de los índices de vegetación en diferentes ambientes. Asimismo,

generar nuevos modelos con una mayor cantidad de datos que le permitan a los algoritmos entrenarse para futuras predicciones en la implementación de la tecnología en los programas de mejora genética.

Es importante investigar en la generación de modelos digitales de terreno y de superficie en áreas con cierta pendiente y evaluar la precisión de estos modelos para la predicción de altura de planta del sorgo.

Además, se recomienda explorar el uso de sensores multiespectrales de bajo costo con el propósito de hacer esta tecnología más asequible a los programas de mejora genética y a los agricultores en general.

Finalmente, considerar la generación de un Sistema de Información geográfica en los programas de mejora genética como un insumo más para la toma de decisiones que permita a futuro un monitoreo en tiempo real de los materiales genéticos en estudio.

Literatura Citada

- Aasen, H., Burkart, A., Bolten, A., & Bareth, G. (2015). Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108, 245–259. <https://doi.org/10.1016/j.isprsjprs.2015.08.002>
- Adamchuk, V., Perk, R., & Schepers, J. (2003). Precision Agriculture: Applications of Remote Sensing in Site-Specific Management. *University of Nebraska-Lincoln Extension*. 705. <https://doi.org/10.2478/gein-2014-0007>
- Ajeigbe, H., Angarawai, T., Akinseye, F., Inuwa, A., AbdulAzeez, T., & Vabi, M. (2020). Handbook on Improved agronomic practices of sorghum production in North East Nigeria (Issue March 2021). <https://www.researchgate.net/publication/349733998>
- Alvarez-Vanhard, E., Corpetti, T., & Houet, T. (2021). UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of Remote Sensing*, 3(January), 100019. <https://doi.org/10.1016/j.srs.2021.100019>
- Araus, J. L., & Kefauver, S. C. (2018). Breeding to adapt agriculture to climate change: affordable phenotyping solutions. *Current Opinion in Plant Biology*, 45, 237–247. <https://doi.org/10.1016/j.pbi.2018.05.003>
- Aswini, M. S., Kiran., Lenka, B., Shaniware, Y. A., Pandey, P., Dash, A. P., & Haokip, S. W. (2023). The Role of Genetics and Plant Breeding for Crop Improvement: Current Progress and Future Prospects. *International Journal of Plant & Soil Science*, 35(20), 190–202. <https://doi.org/10.9734/ijpss/2023/v35i203798>
- Ballester, C., Brinkhoff, J., Quayle, W. C., & Hornbuckle, J. (2019). Monitoring the effects of water stress in cotton using the green red vegetation index and red edge ratio. *Remote Sensing*, 11(7). <https://doi.org/10.3390/RS11070873>
- Barnas, A.F., Darby, B.J., Vandeberg, G.S., Rockwell, R.F., Ellis-Felege, S.N. (2019). A comparison of drone imagery and ground-based methods for estimating the extent of habitat destruction by lesser snow geese (*Anser caerulescens caerulescens*) in La P´erouse Bay, *PLoS ONE* 14(8). <https://doi.org/10.1371/journal.pone.0217049>
- Baye, W., Xie, Q., & Xie, P. (2022). Genetic Architecture of Grain Yield-Related Traits in Sorghum and Maize. *International Journal of Molecular Sciences*, 23(5). <https://doi.org/10.3390/ijms23052405>

- Behera, P. P., Saharia, N., Borah, N., Devi, S. H., & Sarma, R. N. (2022). Sorghum Physiology and Adaptation to Abiotic Stresses. *International Journal of Environment and Climate Change*, 12(10), 1005–1022. <https://doi.org/10.9734/ijecc/2022/v12i1030891>
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, 6(11), 10395–10412. <https://doi.org/10.3390/rs61110395>
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M. L., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>
- Botero Herrera, J. (2009). *Determinación del nivel foliar de nutrientes mediante espectroscopia de reflectancia* [Magister en Geomorfología y Suelos, Universidad Nacional de Colombia]. <https://repositorio.unal.edu.co/handle/unal/2422>
- Braga, P., Crusiol, L. G. T., Nanni, M. R., Caranhato, A. L. H., Fuhrmann, M. B., Nepomuceno, A. L., Neumaier, N., Farias, J. R. B., Koltun, A., Gonçalves, L. S. A., & Mertz-Henning, L. M. (2021). Vegetation indices and NIR-SWIR spectral bands as a phenotyping tool for water status determination in soybean. *Precision Agriculture*, 22(1), 249–266. <https://doi.org/10.1007/s11119-020-09740-4>
- Brocks, S., & Bareth, G. (2018). Estimating barley biomass with crop surface models from oblique RGB imagery. *Remote Sensing*, 10(2), 268. <https://doi.org/10.3390/rs10020268>
- Carrasco, N., Zamora, M., & Melin, A. (2011). Manual de sorgo. In *Inta*. http://inta.gob.ar/sites/default/files/inta_manual_de_sorgo_renglon_191.pdf
- Cheng, T., Song, R., Li, D., Zhou, K., Zheng, H., Yao, X., Tian, Y., Cao, W., & Zhu, Y. (2017). Spectroscopic estimation of biomass in canopy components of paddy rice

- using dry matter and chlorophyll indices. *Remote Sensing*, 9(4). <https://doi.org/10.3390/rs9040319>
- Chivasa, W., Mutanga, O., & Biradar, C. (2020). UAV-based multispectral phenotyping for disease resistance to accelerate crop improvement under changing climate conditions. *Remote Sensing*, 12(15). <https://doi.org/10.3390/RS12152445>
- Chuvieco Salinero, E. (2010). *Teledetección Ambiental: La observación de la Tierra desde el espacio*. Editorial Ariel.
- Ciampitti, I. Sorghum Growth and Development. (2023). Kansas State University, Research and Extension. https://bookstore.ksre.ksu.edu/pubs/sorghum-growth-and-development_MF3234.pdf
- da Silva, E. E., Rojo Baio, F. H., Ribeiro Teodoro, L. P., da Silva Junior, C. A., Borges, R. S., & Teodoro, P. E. (2020). UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation. *Remote Sensing Applications: Society and Environment*, 18. <https://doi.org/10.1016/j.rsase.2020.100318>
- De Souza, C. H. W., Lamparelli, R. A. C., Rocha, J. V., & Magalhães, P. S. G. (2017). Height estimation of sugarcane using an unmanned aerial system (UAS) based on structure from motion (SfM) point clouds. *International Journal of Remote Sensing*, 38(8–10), 2218–2230. <https://doi.org/10.1080/01431161.2017.1285082>
- De Swaef, T., Maes, W. H., Aper, J., Baert, J., Cougnon, M., Reheul, D., Steppe, K., Roldán-Ruiz, I., & Lootens, P. (2021). Applying rgb-and thermal-based vegetation indices from UAVs for high-throughput field phenotyping of drought tolerance in forage grasses. *Remote Sensing*, 13(1), 1–24. <https://doi.org/10.3390/rs13010147>
- Dyson, J., Mancini, A., Frontoni, E., & Zingaretti, P. (2019). Deep learning for soil and crop segmentation from remotely sensed data. *Remote Sensing*, 11(16), 7–9. <https://doi.org/10.3390/rs11161859>
- Dutta, G and Goswami, P. (2020). Application of drone in agriculture: A review. *International Journal of Chemical Studies*, 8(5): 181-187. <https://doi.org/10.22271/chemi.2020.v8.i5d.10529>
- Dutta, RK., Gnananandarao, T., Sharma, A. (2019). Application of random forest regression in the prediction of ultimate bearing capacity of strip footing resting on dense sand overlying loose sand deposit. *J Soft Comput Civ Eng*, 3(4):28–40.

<https://doi.org/10.22115/scce.2019.137910.1080>

- Espinosa-Zúñiga, J.J. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería, investigación y tecnología*, 21(3). <https://doi.org/10.22201/fi.25940732e.2020.21.3.022>
- Fitzgerald, G. J., Rodriguez, D., Christensen, L. K., Belford, R., Sadras, V. O., & Clarke, T. R. (2006). Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments. *Precision Agriculture*, 7(4), 233–248. <https://doi.org/10.1007/s11119-006-9011-z>
- Gano, B., Dembele, J. S. B., Ndour, A., Luquet, D., Beurier, G., Diouf, D., & Audebert, A. (2021). Using uav borne, multi-spectral imaging for the field phenotyping of shoot biomass, leaf area index and height of west african sorghum varieties under two contrasted water conditions. *Agronomy*, 11(5). <https://doi.org/10.3390/agronomy11050850>
- Gerik, T., Bean, B., & Vanderlip, R. (2003). *Sorghum Growth and Development*. <http://glasscock.agrilife.org/files/2015/05/Sorghum-Growth-and-Development.pdf>
- Guo, Y., Senthilnath, J., Wu, W., Zhang, X., Zeng, Z., & Huang, H. (2019). Radiometric calibration for multispectral camera of different imaging conditions mounted on a UAV platform. *Sustainability*, 11(4). <https://doi.org/10.3390/su11040978>
- Hagen, I., Huggel, C., Ramajo, L., Chacón, N., Ometto, J. P., Postigo, J. C., & Castellanos, E. J. (2022). Climate change-related risks and adaptation potential in Central and South America during the 21st century. *Environmental Research Letters*, 17(3). <https://doi.org/10.1088/1748-9326/ac5271>
- Hall, A. J., & Richards, R. A. (2013). Prognosis for genetic improvement of yield potential and water-limited yield of major grain crops. *Field Crops Research*, 143, 18–33. <https://doi.org/10.1016/j.fcr.2012.05.014>
- Hassan, M. A., Yang, M., Fu, L., Rasheed, A., Zheng, B., Xia, X., Xiao, Y., & He, Z. (2019). Accuracy assessment of plant height using an unmanned aerial vehicle for quantitative genomic analysis in bread wheat. *Plant Methods*, 15(1), 1–12. <https://doi.org/10.1186/s13007-019-0419-7>
- Hauser, L. T., Timmermans, J., van der Windt, N., Sil, Â. F., César de Sá, N., Soudzilovskaia, N. A., & van Bodegom, P. M. (2021). Explaining discrepancies

- between spectral and in-situ plant diversity in multispectral satellite earth observation. *Remote Sensing of Environment*, 265. <https://doi.org/10.1016/j.rse.2021.112684>
- James, M. R., & Robson, S. (2012). Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application. *Journal of Geophysical Research: Earth Surface*, 117(3), 1–17. <https://doi.org/10.1029/2011JF002289>
- Janga, B.; Asamani, G.P.; Sun, Z.; Cristea, N. (2023). A Review of Practical AI for Remote Sensing in Earth Sciences. *Remote Sensing*, 15(16), 4112. <https://doi.org/10.3390/rs15164112>
- Jeong JH, Resop JP, Mueller ND, Fleisher DH, Yun K, Butler EE, et al. (2016). Random Forests for Global and Regional Crop Yield Predictions. *PLoS ONE* 11(6), e0156571. <https://doi.org/10.1371/journal.pone.0156571>
- Jiang, Q., Fang, S., Peng, Y., Gong, Y., Zhu, R., Wu, X., Ma, Y., Duan, B., & Liu, J. (2019). UAV-based biomass estimation for rice-combining spectral, TIN-based structural and meteorological features. *Remote Sensing*, 11(7). <https://doi.org/10.3390/RS11070890>
- Jiya, E., Illiyasu, U., & Akinyemi, M. (2023). Rice Yield Forecasting: A Comparative Analysis of Multiple Machine Learning Algorithms. *Journal of Information Systems and Informatics*, 5(2), 785-799. <https://doi.org/10.51519/journalisi.v5i2.506>
- Johansen, K., Morton, M. J. L., Malbeteau, Y., Aragon, B., Al-Mashharawi, S., Ziliani, M., Angel, Y., Fiene, G., Negrao, S., Mousa, M. A. A., Tester, M. A., & McCabe, M. F. (2019). Predicting biomass and yield at harvest of salt-stressed tomato plants using uav imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 407–411. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-407-2019>
- Kanke, Y., Tubaña, B., Dalen, M., & Harrell, D. (2016). Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. *Precision Agriculture*, 17(5), 507–530. <https://doi.org/10.1007/s11119-016-9433-1>
- Kawashima, S., & Nakatani, M. (1998). An algorithm for estimating chlorophyll content in

- leaves using a video camera. *Annals of Botany*, 81(1), 49–54.
<https://doi.org/10.1006/anbo.1997.0544>
- Kazungu, F. K., Muindi, E. M., & Mulinge, J. M. (2023). Overview of Sorghum (*Sorghum bicolor*. L), its Economic Importance, Ecological Requirements and Production Constraints in Kenya. *International Journal of Plant & Soil Science*, 62–71.
<https://doi.org/10.9734/ijpss/2023/v35i12744>
- Kumar, C., Mubvumba, P., Huang, Y., Dhillon, J., & Reddy, K. (2023). Multi-Stage Corn Yield Prediction Using High-Resolution UAV Multispectral Data and Machine Learning Models. *Agronomy*, 13(5), 1–23.
<https://doi.org/10.3390/agronomy13051277>
- Li, J., Schachtman, D. P., Creech, C. F., Wang, L., Ge, Y., & Shi, Y. (2022). Evaluation of UAV-derived multimodal remote sensing data for biomass prediction and drought tolerance assessment in bioenergy sorghum. *Crop Journal*, 10(5), 1363–1375.
<https://doi.org/10.1016/j.cj.2022.04.005>
- Li, J., Shi, Y., Veeranampalayam-Sivakumar, A. N., & Schachtman, D. P. (2018). Elucidating sorghum biomass, nitrogen and chlorophyll contents with spectral and morphological traits derived from unmanned aircraft system. *Frontiers in Plant Science*, 9, 1–12. <https://doi.org/10.3389/fpls.2018.01406>
- Li, J., Zhang, F., Qian, X., Zhu, Y., & Shen, G. (2015). Quantification of rice canopy nitrogen balance index with digital imagery from unmanned aerial vehicle. *Remote Sensing Letters*, 6(3), 183–189. <https://doi.org/10.1080/2150704X.2015.1021934>
- Liu, S., Jin, X., Bai, Y., Wu, W., Cui, N., Cheng, M., Liu, Y., Meng, L., Jia, X., Nie, C., Yin, D. (2023). UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background. *International Journal of Applied Earth Observation and Geoinformation*, 121, 103383.
<https://doi.org/10.1016/j.jag.2023.103383>
- Liu, Q., Wang, Y., Yang, J., Zhang, W., Wang, H., Li, F., Wang, G., Huo, Y., & Han, J. (2023). Smartagb : Aboveground Biomass Estimation of Sorghum Based on Spatial Resolution , Machine Learning and Vegetation Index. *EAI Endorsed Transactions on Internet of Things*, 9(1). <https://doi.org/10.4108/eetiot.v9i1.2904>
- Liu, X., Lian, X., Yang, W., Wang, F., Han, Y., Zhang, Y. (2022). Accuracy Assessment

- of a UAV Direct Georeferencing Method and Impact of the Configuration of Ground Control Points. *Drones*, 6(2), 30. <https://doi.org/10.3390/drones6020030>
- Lü, G.hua., Wu., Y.feng., Bai, W. bo., Ma, B., Wang, C. yan., Song, J. qing. (2013). Influence of High Temperature Stress on Net Photosynthesis, Dry Matter Partitioning and Rice Grain Yield at Flowering and Grain Filling Stages. *Journal of Integrative Agriculture*, 12(4), 603–609. [https://doi.org/10.1016/S2095-3119\(13\)60278-6](https://doi.org/10.1016/S2095-3119(13)60278-6)
- Lussem, U., Bolten, A., Gnyp, M. L., Jasper, J., & Bareth, G. (2018). Evaluation of RGB-based vegetation indices from UAV imagery to estimate forage yield in Grassland. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(3), 1215–1219. <https://doi.org/10.5194/isprs-archives-XLII-3-1215-2018>
- Malambo, L., Popescu, S. C., Murray, S. C., Putman, E., Pugh, N. A., Horne, D. W., Richardson, G., Sheridan, R., Rooney, W. L., Avant, R., Vidrine, M., McCutchen, B., Baltensperger, D., & Bishop, M. (2018). Multitemporal field-based plant height estimation using 3D point clouds generated from small unmanned aerial systems high-resolution imagery. *International Journal of Applied Earth Observation and Geoinformation*, 64, 31–42. <https://doi.org/10.1016/j.jag.2017.08.014>
- Mandal, S., Bhattacharya, S., & Paul, S. (2022). Assessing the impact of coal-fired thermal power plant emissions on surrounding vegetation health using geoinformatics: a case study. *Safety in Extreme Environments*, 4(2), 81–100. <https://doi.org/10.1007/s42797-022-00054-4>
- Marques Ramos, A. P., Prado Osco, L., Garcia Furuya, D.E., Nunes Gonçalves, W., Cordeiro Santana, D., Pereira Ribeiro, L., da Silva Junior, C.A., Capristo-Silva, G.F., Li, J., Rojo Baio, F.H., Marcato Junior, J., Teodoro, P.E., & Pistori, H. (2020). A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. *Computers and Electronics in Agriculture*, 178, 105791. <https://doi.org/10.1016/j.compag.2020.105791>
- Martínez, R., & Solís, G. (2018). Caracterización Espectral y Detección de Flecha Seca en Palma Africana en Puntarenas, Costa Rica. *Revista Geográfica de América Central*, 2(61), 349–377. <https://doi.org/10.15359/rgac.61-2.13>

- Masjedi, A., Crawford, M. M., Carpenter, N. ., & Tuinstra, M. R. (2020). PREDICTION OF SORGHUM BIOMASS USING TIME SERIES UAV-BASED HYPERSPECTRAL and LIDAR DATA. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3912–3915. <https://doi.org/10.1109/IGARSS39084.2020.9323425>
- Matias, F. I., Caraza-Harter, M. V., & Endelman, J. B. (2020). FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. *Plant Phenome Journal*, 3(1), 1–6. <https://doi.org/10.1002/ppj2.20005>
- Mbaye, M., Ndour, A., Gano, B., Dembele, J. S. ., Luquet, D., Beurrier, G., & Audebert, A. (2021). UV Method Based on Multispectral Imaging for Field Phenotyping. In N. . Kane, D. Foncéka, & T. . Dalton (Eds.), *Crop Adaptation and Improvement for Drought-Prone Environments* (Issue December, pp. 171–187).
- Mesas-Carrascosa, F. J., Torres-Sánchez, J., Clavero-Rumbao, I., García-Ferrer, A., Peña, J. M., Borra-Serrano, I., & López-Granados, F. (2015). Assessing optimal flight parameters for generating accurate multispectral orthomosaics by uav to support site-specific crop management. *Remote Sensing*, 7(10), 12793–12814. <https://doi.org/10.3390/rs71012793>
- Micasense. (2023). Use of Calibrated Reflectance Panels For MicaSense Data. August,30. <https://support.micasense.com/hc/en-us/articles/115000765514-Use-of-Calibrated-Reflectance-Panels-For-MicaSense-Data>
- MicaSense. (2020). MicaSense Altum and DLS2 Integration Guide (Issue 10). https://support.micasense.com/hc/en-us/article_attachments/360073921173/AltumDLS2IntegrationGuideRev10.pdf
- Ministerio de Ambiente y Energía, M. (2022). Mapa de zonas de vida de Costa Rica. Sistema Nacional de Información Territorial, Instituto Geográfico Nacional.
- Mir, R.R., Reynolds, M., Pinto, F., Khan, M.A., Bhat, M.A. (2019). High-throughput phenotyping for crop improvement in the genomics era. *Plant Sci.* 282, 60–72. <https://doi.org/10.1016/j.plantsci.2019.01.007>
- Moles, A. T., Warton, D. I., Warman, L., Swenson, N. G., Laffan, S. W., Zanne, A. E., Pitman, A., Hemmings, F. A., & Leishman, M. R. (2009). Global patterns in plant height. *Journal of Ecology*, 97(5), 923–932. <https://doi.org/10.1111/j.1365-2745.2009.01526.x>

- Murillo Sandoval, P y Carbonell González, J. (2012). Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia. Cenicaña. https://www.cenicana.org/pdf_privado/documentos_no_seridados/libro_percepcion_remota/principios-y-aplicaciones_percepcion-remota.pdf
- Nakasagga, S., Adak, A., Murray, S. C., Rooney, W. L., Hoffmann, L., Wilde, S., Lindsey, R., Nabukalu, P., & Cox, S. (2022). Prediction of regrowth and biomass of perennial sorghum using unoccupied aerial systems. *Crop Science*, 62(6), 2107–2121. <https://doi.org/10.1002/csc2.20758>
- Njane, SN., Tsuda, S., Van Marrewijk, BM., Polder, G., Katayama, K., Tsuji, H. (2023) Effect of varying UAV height on the precise estimation of potato crop growth. *Frontiers in Plant Sciences*. 14,1233349. <https://doi.org/10.3389/fpls.2023.1233349>
- Orozco Barrantes, E., & Sánchez Ledezma, W. (2018). Evaluación de variedades e híbridos de sorgo forrajero en condiciones de Bosque Húmedo Tropical. *Alcances Tecnológicos*, 8(1), 45–54. <https://doi.org/10.35486/at.v8i1.78>
- Pargiela, K. (2023). Optimising UAV Data Acquisition and Processing for Photogrammetry: A Review. *Geomatics and Environmental Engineering*, 17(3), 29–59. <https://doi.org/10.7494/geom.2023.17.3.29>
- Peña, L., Rentería, V., Velásquez, C., Ojeda, M. L., & Barrera, E. (2018). Absorbancia y reflectancia de hojas de Ficus contaminadas con nanopartículas de plata. *Revista Mexicana de Física*, 65(1), 95–105. <https://doi.org/10.31349/REVMEXFIS.65.95>
- Peng, B., Guan, K., Tang, J., Ainsworth, E. A., Asseng, S., Bernacchi, C. J., Cooper, M., Delucia, E. H., Elliott, J. W., Ewert, F., Grant, R. F., Gustafson, D. I., Hammer, G. L., Jin, Z., Jones, J. W., Kimm, H., Lawrence, D. M., Li, Y., Lombardozzi, D. L., ... Zhou, W. (2020). Towards a multiscale crop modelling framework for climate change adaptation assessment. In *Nature Plants* (Vol. 6, Issue 4). Springer US. <https://doi.org/10.1038/s41477-020-0625-3>
- Peroni Venancio, L., Chartuni Mantovani, E., do Amaral, C. H., Usher Neale, C. M., Zution Gonçalves, I., Filgueiras, R., & Coelho Eugenio, F. (2020). Potential of using spectral vegetation indices for corn green biomass estimation based on their relationship with the photosynthetic vegetation sub-pixel fraction. *Agricultural Water Management*, 236, 106155. <https://doi.org/10.1016/j.agwat.2020.106155>

- Pix4D. (2017). Pix4Dmapper4.1 USER MANUAL. Lausanne, Switzerland. <https://support.pix4d.com/hc/en-us/articles/204272989>
- Poncet, A.M., Knappenberger, T., Brodbeck, C., Shaw, J.N., Ortiz, B.V. (2019). Multispectral UAS Data Accuracy for Different Radiometric Calibration Methods. *Remote Sensing*, 11(16), 1917; <https://doi.org/10.3390/rs11161917>
- Prasad, N.R., Patel, N.R. & Danodia, A. (2021). Crop yield prediction in cotton for regional level using random forest approach. *Spatial Information Research. Res.* **29**, 195–206. <https://doi.org/10.1007/s41324-020-00346-6>
- Prasad, A. M., Iverson, L. R., & Liaw, A. (2006). Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. *Ecosystems*, 9(2), 181–199. <https://doi.org/10.1007/s10021-005-0054-1>
- Probst, A., Gatziolis, D., & Strigul, N. (2018). Intercomparison of photogrammetry software for three-dimensional vegetation modelling. *Royal Society Open Science*, 5(7). <https://doi.org/10.1098/rsos.172192>
- QGIS Development Team (2024). QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>
- R Core Team. (2019). R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria. <https://www.R-project.org/>.
- Rakshit, S., & Bellundagi, A. (2018). Conventional breeding techniques in sorghum. In *Breeding Sorghum for Diverse End Uses* (pp. 77–91). oodhead Publishing Series in Food Science, Technology and Nutrition. <https://doi.org/10.1016/B978-0-08-101879-8.00005-X>
- Rakshit, S., & Gomashe, S. (2013). Basics of plant breeding with reference to sorghum. In S. Rakshit & J. . Patil (Eds.), *Basics of sorghum breeding and AICSIP data management* (pp. 9–16).
- Ramoelo, A., Cho, M. A., Mathieu, R., Madonsela, S., van de Kerchove, R., Kaszta, Z., & Wolff, E. (2015). Monitoring grass nutrients and biomass as indicators of rangeland quality and quantity using random forest modelling and WorldView-2 data. *International Journal of Applied Earth Observation and Geoinformation*, 43, 43–54. <https://doi.org/10.1016/j.jag.2014.12.010>
- Ranjan, R., Chandel, A. K., Khot, L. R., Bahlol, H. Y., Zhou, J., Boydston, R. A., & Miklas,

- P. N. (2019). Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. *Information Processing in Agriculture*, 6(4), 502–514. <https://doi.org/10.1016/j.inpa.2019.01.005>
- Rao, S. S., Akula, U., & Seetharama, N. (2008). Characterizing phenology and growth stages of sorghum hybrids. National Research Centre for Sorghum, 3–8. <https://doi.org/10.13140/2.1.4841.8246>
- Read, J. M., & Torrado, M. (2009). Remote Sensing. In International Encyclopedia of Human Geography. <https://doi.org/10.1016/B978-008044910-4.00508-3>
- Remondino, F., Barazzetti, L., Nex, F., Scaioni, M., Sarazzi, D. (2011). UAV photogrammetry for mapping and 3D modeling-Current status and future perspectives. In International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. <https://isprs-archives.copernicus.org/articles/XXXVIII-1-C22/25/2011/>
- Rodriguez, O. (2023). *regressoR: Regression Data Analysis System*. R package version 3.0.2, <https://CRAN.R-project.org/package=regressoR>.
- Roozeboom, K., & Vara Prasad, P. V. (2019). Sorghum growth and development. In Sorghum: State of the Art and Future Perspectives (pp. 155–172). <https://doi.org/10.2134/agronmonogr58.2014.0062>
- Sanz-Ablanedo, E., Chandler, J.H., Rodriguez-Perez, J.R, Ordonez, C. (2018). Accuracy of Unmanned Aerial Vehicle (UAV) and SfM Photogrammetry Survey as a Function of the Number and Location of Ground Control Points Used. *Remote Sensing*, 10:1606. <https://doi.org/10.3390/rs10101606>
- Saravia, D., Salazar, W., Valqui-Valqui, L., Quille-Mamani, J., Porrás-Jorge, R., Corredor, F. A., Barboza, E., Vásquez, H. V., Casas Diaz, A. V., & Arbizu, C. I. (2022). Yield Predictions of Four Hybrids of Maize (*Zea mays*) Using Multispectral Images Obtained from UAV in the Coast of Peru. *Agronomy*, 12(11), 1–14. <https://doi.org/10.3390/agronomy12112630>
- Sarkar, S., Cazenave, A.B., Oakes, J., McCall, D., Thomason, W., Abbot, L., Balota, M. 2020. High-throughput measurement of peanut canopy height using digital surface models. *The Plant Phenome Journal*, 3(1), :e20003. <https://doi.org/10.1002/ppj2.20003>

- Saucedo, O., Iglesias, J., Wencomo, H. B., Reyes, F., Oquendo, G., & Milián, I. (2010). Caracterización y potencialidades del grano de sorgo (*Sorghum bicolor* L. Moench). *Pastos y Forrajes*, 33(1), 1–1.
- Seifertm, E., Seifert, S., Vogt, H., Drew, D., van Aardt, J., Kunneke, A., Seifert, T. (2019) Influence of Drone Altitude, Image Overlap, and Optical Sensor Resolution on Multi-View Reconstruction of Forest Images. *Remote Sensing*, 11:1252. <https://doi.org/10.3390/rs111101252>
- Serrano, L., Filella, I., & Peñuelas, J. (2000). Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science*, 40(3), 723–731. <https://doi.org/10.2135/cropsci2000.403723x>
- Shu, M., Li, Q., Ghafoor, A., Zhu, J., Li, B., & Ma, Y. (2023). Using the plant height and canopy coverage to estimation maize aboveground biomass with UAV digital images. *European Journal of Agronomy*, 151(September), 126957. <https://doi.org/10.1016/j.eja.2023.126957>
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), 1–31. <https://doi.org/10.3390/rs12193136>
- Stamenković, O. S., Siliveru, K., Veljković, V. B., Banković-Ilić, I. B., Tasić, M. B., Ciampitti, I. A., Đalović, I. G., Mitrović, P. M., Sikora, V., & Prasad, P. V. V. (2020). Production of biofuels from sorghum. *Renewable and Sustainable Energy Reviews*, 124, 109769. <https://doi.org/10.1016/j.rser.2020.109769>
- Stavrakoudis, D., Katsantonis, D., Kadoglidou, K., Kalaitzidis, A., & Gitas, I. Z. (2019). Estimating rice agronomic traits using drone-collected multispectral imagery. *Remote Sensing*, 11(5), 545. <https://doi.org/10.3390/rs11050545>
- Strobl, C., Boulesteix, A. L., Kneib, T., Augustin, T., & Zeileis, A. (2008). Conditional variable importance for random forests. *BMC Bioinformatics*, 9, 1–11. <https://doi.org/10.1186/1471-2105-9-307>
- Tang, L., & Shao, G. (2015). Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, 26(4), 791–797. <https://doi.org/10.1007/s11676-015-0088-y>
- Tayade, R., Yoon, J., Lay, L., Khan, A. L., Yoon, Y., & Kim, Y. (2022). Utilization of

- Spectral Indices for High-Throughput Phenotyping. *Plants*, 11(13). <https://doi.org/10.3390/plants11131712>
- Tian-Zhu, X., Gui-Song, X., Liangpei Z. (2018). Unmanned Aerial Vehicle-Based Remote Sensing: Techniques, applications, and prospects. *Geoscience and Remote Sensing*, 7(3), 9-63. <https://doi.org/10.1109/MGRS.2019.2918840>
- Trethowan, R.M. (2014). Defining a Genetic Ideotype for Crop Improvement. In: Fleury, D., Whitford, R. (eds) *Crop Breeding. Methods in Molecular Biology*, vol 1145. Humana Press, New York, NY. https://doi.org/10.1007/978-1-4939-0446-4_1
- United Nations. (2017). World population projected to reach 9.8 billion in 2050, and 11.2 billion in 2100. In UN Department of Economic and Social Affairs. https://www.un.org/en/development/desa/population/events/pdf/other/21/21June_FINAL_PRESS_RELEASE_WPP17.pdf
- Varela, S., Pederson, T., Bernacchi, C. J., & Leakey, A. D. B. (2021). Understanding Growth Dynamics and Yield Prediction of Sorghum Using High Temporal Resolution UAV Imagery Time Series and Machine Learning. *Remote Sensing*, 13(9), 1–17.
- Vinutha, K. S., Anil Kumar, G. S., Blümmel, M., & Srinivasa Rao, P. (2017). Evaluation of yield and forage quality in main and ratoon crops of different sorghum lines. *Tropical Grasslands*, 5(1), 40–49. [https://doi.org/10.17138/TGFT\(5\)40-49](https://doi.org/10.17138/TGFT(5)40-49)
- Walter, A., Liebisch, F., & Hund, A. (2015). Plant phenotyping: From bean weighing to image analysis. *Plant Methods*, 11(1), 1–11. <https://doi.org/10.1186/s13007-015-0056-8>
- Wan, L., Cen, H., Zhu, J., Zhang, J., Zhu, Y., Sun, D., Du, X., Zhai, L., Weng, H., Li, Y., Li, X., Bao, Y., Shou, J., & He, Y. (2020). Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer – a case study of small farmlands in the South of China. *Agricultural and Forest Meteorology*, 29, 108096. <https://doi.org/10.1016/j.agrformet.2020.108096>
- Wang, X., Singh, D., Marla, S., Morris, G., & Poland, J. (2018). Field-based high-throughput phenotyping of plant height in sorghum using different sensing technologies. *Plant Methods*, 14(1), 1–16. <https://doi.org/10.1186/s13007-018-0324-5>
- Watt, M., Fiorani, F., Usadel, B., Rascher, U., Muller, O., & Schurr, U. (2020).

- Phenotyping: New Windows into the Plant for Breeders. *Annual Review of Plant Biology*, 71, 689–712. <https://doi.org/10.1146/annurev-arplant-042916-041124>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Whitney, D. (1998). Fertilizer requirements. In Grain sorghum production handbook (pp. 12–15). Kansas State University Agricultural Experiment Station and Cooperative Extension Service. <https://bookstore.ksre.ksu.edu/pubs/c687.pdf>
- Wu, B., Zhang, M., Zeng, H., Tian, F., Potgieter, A.B., Qin, X., Yan, N., Chang, S., Zhao, Y., Dong, Q., Boken, V., Plotnikov, D., Guo, H., Wu, F., Zhao, H., Deronde, B., Tits, L., Loupian, E. (2023). Challenges and opportunities in remote sensing-based crop monitoring: a review. *National Science Review*, 10(4). <https://doi.org/10.1093/nsr/nwac290>
- Xiang, T. Z., Xia, G. S., & Zhang, L. (2019). Mini-Unmanned Aerial Vehicle-Based Remote Sensing: Techniques, applications, and prospects. *IEEE Geoscience and Remote Sensing Magazine*, 7(3), 29–63. <https://doi.org/10.1109/MGRS.2019.2918840>
- Xie, Q., Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., Casa, R., Pignatti, S., Laneve, G., Pascucci, S., Dong, Y., & Ye, H. (2018). Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1482–1492. <https://doi.org/10.1109/JSTARS.2018.2813281>
- Yang, B., Zhu, W., Rezaei, E. E., Li, J., Sun, Z., & Zhang, J. (2022). The Optimal Phenological Phase of Maize for Yield Prediction with High-Frequency UAV Remote Sensing. *Remote Sensing*, 14(7), 1–18. <https://doi.org/10.3390/rs14071559>
- Yang, G., Liu, J., Zhao, C., Li, Z., Huang, Y., Yu, H., Xu, B., Yang, X., Zhu, D., Zhang, X., Zhang, R., Feng, H., Zhao, X., Li, Z., Li, H., & Yang, H. (2017). Unmanned aerial vehicle remote sensing for field-based crop phenotyping: Current status and perspectives. *Frontiers in Plant Science*, 8. <https://doi.org/10.3389/fpls.2017.01111>
- Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H., & Xu, B. (2017). Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot

- hyperspectral sensor and crop height improved models. *Remote Sensing*, 9(7), 708. <https://doi.org/10.3390/rs9070708>
- Zeybek, M; Taşkaya, S; Elkhachy, I; Tarolli, P. Improving the Spatial Accuracy of UAV Platforms Using Direct Georeferencing Methods: An Application for Steep Slopes. (2023). *Remote Sensing*, 15(10), 2700. <https://doi.org/10.3390/rs15102700>
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, 13(6), 693–712. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, J., Wang, C., Yang, C., Xie, T., Jiang, Z., Hu, T., et al. (2020). Assessing the effect of real spatial resolution of in situ UAV multispectral images on seedling rapeseed growth monitoring. *Remote Sensing*. 12(7), 1207. <https://doi.org/10.3390/rs12071207>
- Zhao, Y., Zheng, B., Chapman, S. C., Laws, K., George-Jaeggli, B., Hammer, G. L., Jordan, D. R., & Potgieter, A. B. (2021). Detecting Sorghum Plant and Head Features from Multispectral UAV Imagery. *Plant Phenomics*. <https://doi.org/10.34133/2021/9874650>
- Zheng, H., Cheng, T., Zhou, M., Li, D., Yao, X., Tian, Y., Cao, W., & Zhu, Y. (2019). Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery. *Precision Agriculture*, 20(3), 611–629. <https://doi.org/10.1007/s11119-018-9600-7>

Anexos

Anexo 1. Especificaciones de la lente e imágenes del sensor Micasense altum AL05.

	Multispectral	Thermal
Pixel size	3.45 μm	12 μm
Resolution	2064 x 1544 px (3.2 MP x 5 imagers)	160 x 120 px (0.01 K)
Aspect ratio	4 : 3	4 : 3
Sensor size	7.12 x 5.33 mm (8.9 mm diagonal)	1.92 x 1.44 mm
Focal length	8 mm	1.77 mm
Field of view (h x v)	48° x 36.8°	57° x 44.3°
Thermal sensitivity	n/a	< 50 mK
Thermal accuracy	n/a	+/- 5 K
Output bit depth	12-bit	14-bit
GSD @ 120 m (~400 ft)	5.2 cm	81 cm
GSD @ 60 m (~200 ft)	2.1 cm	41 cm

Fuente: Micasense, 2020.

Anexo 2. Información de post-procesamiento de puntos de control de campo.

Informe del Procesamiento GNSS - Resumen



Pedir detalles

General

Procesado en: 2023-12-05 13:45:22
SBC versión: 7.8.1.438

Detalles de Usuario

Nombre de usuario: Mevslizano
Nombre: Melvin Lizano Araya
Empresa: UCR
E-Mail: melvslizano@hotmail.com

Resultados de Puntos

ID- Punto	Tipo de Solución	Ocupaciones / Líneas base	Latitud WGS84
1	Fijo (Fase)	1/5	10° 24.86 N

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Cartesiana X - WGS84	Cartesiana Y - WGS84	Cartesiana Z - WGS84	D.Est X	D.Est Y	D.Est Z
1	Fijo (Fase)	1/5	532082.1669 m	-6252650.3750 m	1137294.5669 m	0.0021 m	0.0038 m	0.0019 m

1 - 2023-12-05 11:44:11

Resultados de Ocupación de Punto

Marker Name: 1 Tipo de Receptor / SN: GEOMAX ZENITH40 / 1791850
Tipo de Antena / SN: GMXZENITH40 NONE / -
Inicio de Ocupación: 2023-12-05 11:44:11 Fin de Ocupación: 2023-12-05 11:46:37

Resumen de punto promedio: 1

Promedio ponderado:
Sí

WGS84 Latitud:	10° 20' 24.8630" N	D.Est latitud:	0.0018 m
WGS84 Longitud:	85° 08' 09.6571" W	D.Est longitud:	0.0020 m
WGS84 Altura.Elíp:	21.3686 m	DE Alt:	0.0039 m
WGS84 Cartesiana X:	532082.1669 m	D.Est X:	0.0021 m
WGS84 Cartesiana Y:	-6252650.3750 m	D.Est Y:	0.0038 m
WGS84 Cartesiana Z:	1137294.5669 m	D.Est Z:	0.0019 m
X:	-	D.Est X:	-
Coordenada Y:	-	D.Est Y:	-
Altura Elipsoidal:	-	DE Alt:	-
Altura Ortom.:	-		

Resumen de líneas de base 1

ID- Punto	Referencia	Longitud de Línea Base [m]	3D QC [m]	ΔX	ΔY	ΔZ	X	Y	Z
1							532082.1669 m	-6252650.3750 m	1137294.5669 m
	CIQE	77261.0122 m	0.0047 m	0.0000 m	0.0000 m	0.0000 m	532082.1669 m	-6252650.3750 m	1137294.5669 m
	NYCO	41140.5109 m	0.0932 m	0.1975 m	-0.2042 m	0.0977 m	532081.9694 m	-6252650.1709 m	1137294.4693 m
	PUNT	51939.3034 m	0.0171 m	-0.0626 m	0.0133 m	-0.0302 m	532082.2295 m	-6252650.3884 m	1137294.5971 m
	QUEP	146700.7542 m	0.0328 m	-0.0101 m	-0.0025 m	-0.1281 m	532082.1770 m	-6252650.3725 m	1137294.6951 m
	RIDC	127899.8268 m	0.0272 m	0.0049 m	0.1232 m	-0.1341 m	532082.1620 m	-6252650.4983 m	1137294.7010 m

Informe del Procesamiento GNSS - Resumen



Pedir detalles

General

Procesado en: 2023-12-08 11:21:49
SBC versión: 7.8.1.438

Detalles de Usuario

Nombre de usuario: Mevslizano
Nombre: Melvin Lizano Araya
Empresa: UCR
E-Mail: mevslizano@hotmail.com

Resultados de Puntos

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Lat WG
Canas1	xRTK	1/5	10 27 N

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Cartesiana X - WGS84	Cartesiana Y - WGS84	Cartesiana Z - WGS84	D.Est X	D.Est Y	D.Est Z
Canas1	xRTK	1/5	532080.3745 m	-6252637.7468 m	1137363.1732 m	0.0132 m	0.0281 m	0.0394 m

Canas1 - 2023-12-05 12:09:26

Resultados de Ocupación de Punto

Marker Name: Canas1
Tipo de Receptor / SN: GEOMAX ZENITH40 / 1791840
Tipo de Antena / SN: GMXZENITH40 NONE / -
Inicio de Ocupación: 2023-12-05 12:09:26
Fin de Ocupación: 2023-12-05 12:25:47

Resumen de punto promedio: Canas1

Promedio ponderado:

Si								
WGS84 Latitud:	10° 20' 27.1340" N	D.Est latitud:	0.0398 m					
WGS84 Longitud:	85° 08' 09.6806" W	D.Est longitud:	0.0130 m					
WGS84 Altura.Elíp:	21.1554 m	DE Alt:	0.0277 m					
WGS84 Cartesiana X:	532080.3745 m	D.Est X:	0.0132 m					
WGS84 Cartesiana Y:	-6252637.7468 m	D.Est Y:	0.0281 m					
WGS84 Cartesiana Z:	1137363.1732 m	D.Est Z:	0.0394 m					
X:	-	D.Est X:	-					
Coordenada Y:	-	D.Est Y:	-					
Altura Elipsoidal:	-	DE Alt:	-					
Altura Ortom.:	-							

Resumen de líneas de base Canas1

ID-Punto	Referencia	Longitud de Línea Base [m]	3D QC [m]	ΔX	ΔY	ΔZ	X	Y	Z
Canas1							532080.3745 m	-6252637.7468 m	1137363.1732 m
	CHLS	89466.3300 m	0.0074 m	-0.1441 m	-0.5078 m	0.0837 m	532080.5187 m	-6252637.2390 m	1137363.0896 m
	CIQE	77263.4297 m	0.0055 m	-0.0194 m	0.0215 m	-0.0667 m	532080.3939 m	-6252637.7683 m	1137363.2399 m
	LBRA	46068.8033 m	0.0329 m	0.1236 m	-0.9776 m	0.0245 m	532080.2509 m	-6252636.7692 m	1137363.1487 m
	NYCO	41176.8238 m	0.0070 m	0.0198 m	-0.1953 m	0.2034 m	532080.3547 m	-6252637.5515 m	1137362.9698 m
	PUNT	51993.3127 m	0.0042 m	0.0110 m	-0.0162 m	0.0293 m	532080.3635 m	-6252637.7306 m	1137363.1439 m

Informe del Procesamiento GNSS - Resumen



Pedir detalles

General

Procesado en: 2023-12-08 11:30:38
SBC versión: 7.8.1.438

Detalles de Usuario

Nombre de usuario: Mevslizano
Nombre: Melvin Lizano Araya
Empresa: UCR
E-Mail: mevslizano@hotmail.com

Resultados de Puntos

ID- Punto	Tipo de Solución	Ocupaciones / Líneas base	Latitud WGS
CAN3	Fijo (Fase)	1/5	10° 24.8 N

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Cartesiana X - WGS84	Cartesiana Y - WGS84	Cartesiana Z - WGS84	D.Est X	D.Est Y	D.Est Z
CAN3	Fijo (Fase)	1/5	532051.4844 m	-6252652.6625 m	1137295.0839 m	0.0057 m	0.0162 m	0.0230 m

CAN3 - 2023-12-05 12:49:02

Resultados de Ocupación de Punto

Marker Name: CAN3
Tipo de Receptor / SN: GEOMAX ZENITH40 / 1791850
Inicio de Ocupación: 2023-12-05 12:49:02
Tipo de Antena / SN: GMXZENITH40 NONE / -
Fin de Ocupación: 2023-12-05 13:06:51

Resumen de punto promedio: CAN3

Promedio ponderado:

WGS84 Latitud:	10° 20' 24.8814" N	D.Est latitud:	0.0232 m
WGS84 Longitud:	85° 08' 10.6684" W	D.Est longitud:	0.0056 m
WGS84 Altura,Elip:	21.1443 m	DE Alt:	0.0160 m
WGS84 Cartesiana X:	532051.4844 m	D.Est X:	0.0057 m
WGS84 Cartesiana Y:	-6252652.6625 m	D.Est Y:	0.0162 m
WGS84 Cartesiana Z:	1137295.0839 m	D.Est Z:	0.0230 m
X:	-	D.Est X:	-
Coordenada Y:	-	D.Est Y:	-
Altura Elipsoidal:	-	DE Alt:	-
Altura Ortom.:	-		

Resumen de líneas de base CAN3

ID- Punto	Referencia	Longitud de Línea Base [m]	3D QC [m]	ΔX	ΔY	ΔZ	X	Y	Z
CAN3							532051.4844 m	-6252652.6625 m	1137295.0839 m
	CHLS	89541.5214 m	0.0417 m	1.0580 m	-0.3966 m	-0.1283 m	532050.4264 m	-6252652.2658 m	1137295.2122 m
	CIQE	77291.7957 m	0.0046 m	0.0091 m	0.0255 m	-0.0605 m	532051.4753 m	-6252652.6880 m	1137295.1444 m
	LBRA	46095.7840 m	0.0035 m	-0.0806 m	-0.4638 m	0.1242 m	532051.5651 m	-6252652.1987 m	1137294.9597 m
	NYCO	41114.6124 m	0.0274 m	0.2469 m	-0.0199 m	0.0684 m	532051.2376 m	-6252652.6426 m	1137295.0155 m
	PUNT	51959.4883 m	0.0021 m	-0.0023 m	-0.0056 m	0.0109 m	532051.4867 m	-6252652.6569 m	1137295.0729 m

Informe del Procesamiento GNSS - Resumen



Pedir detalles

Resultados de Puntos

General

Procesado en: 2023-12-08 11:22:21
SBC versión: 7.8.1.438

Detalles de Usuario

Nombre de usuario: Mevslizano
Nombre: Melvín Lizano Araya
Empresa: UCR
E-Mail: mevslizano@hotmail.com

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Lat WG
Canas4	Fijo (Fase)	1/5	10 27 N

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Cartesiana X - WGS84	Cartesiana Y - WGS84	Cartesiana Z - WGS84	D.Est X	D.Est Y	D.Est Z
Canas4	Fijo (Fase)	1/5	532049.4686 m	-6252640.4067 m	1137362.5584 m	0.0007 m	0.0016 m	0.0006 m

Canas4 - 2023-12-05 12:37:47

Resultados de Ocupación de Punto

Marker Name: Canas4
Tipo de Receptor / SN: GEOMAX ZENITH40 / 1791840
Tipo de Antena / SN: GMXZENITH40 NONE / -
Inicio de Ocupación: 2023-12-05 12:37:47
Fin de Ocupación: 2023-12-05 12:57:01

Resumen de punto promedio: Canas4

Promedio ponderado:

Si									
WGS84 Latitud:	10° 20' 27.1142" N	D.Est latitud:	0.0006 m						
WGS84 Longitud:	85° 08' 10.7002" W	D.Est longitud:	0.0007 m						
WGS84 Altura.Elíp:	21.0744 m	DE Alt:	0.0016 m						
WGS84 Cartesiana X:	532049.4686 m	D.Est X:	0.0007 m						
WGS84 Cartesiana Y:	-6252640.4067 m	D.Est Y:	0.0016 m						
WGS84 Cartesiana Z:	1137362.5584 m	D.Est Z:	0.0006 m						
X:	-	D.Est X:	-						
Coordenada Y:	-	D.Est Y:	-						
Altura Elipsoidal:	-	DE Alt:	-						
Altura Ortom.:	-								

Resumen de líneas de base Canas4

ID-Punto	Referencia	Longitud de Línea Base [m]	3D QC [m]	ΔX	ΔY	ΔZ	x	y	z
Canas4							532049.4686 m	-6252640.4067 m	1137362.5584 m
	CHLS	89482.8339 m	0.0277 m	0.2130 m	-0.7101 m	-0.2726 m	532049.2556 m	-6252639.6966 m	1137362.8310 m
	CIQE	77294.5042 m	0.0093 m	0.0689 m	-0.1106 m	-0.1281 m	532049.3997 m	-6252640.2961 m	1137362.6865 m
	LBRA	46046.9025 m	0.0261 m	0.1860 m	-0.8022 m	-0.0471 m	532049.2826 m	-6252639.6045 m	1137362.6054 m
	NYCO	41150.2584 m	0.0019 m	0.0000 m	0.0000 m	0.0000 m	532049.4686 m	-6252640.4067 m	1137362.5584 m
	PUNT	52012.8777 m	0.0047 m	0.1049 m	-0.0217 m	-0.0864 m	532049.3637 m	-6252640.3850 m	1137362.6448 m

Informe del Procesamiento GNSS - Resumen



Pedir detalles

General

Procesado en: 2023-12-08 11:28:39
SBC versión: 7.8.1.438

Detalles de Usuario

Nombre de usuario: Mevslizano
Nombre: Melvin Lizano Araya
Empresa: UCR
E-Mail: melvslizano@hotmail.com

Resultados de Puntos

ID- Punto	Tipo de Solución	Ocupaciones / Líneas base	Latitud WGS84
1	Fijo (Fase)	1/5	10° 2 24.86 N

ID-Punto	Tipo de Solución	Ocupaciones / Líneas base	Cartesiana X - WGS84	Cartesiana Y - WGS84	Cartesiana Z - WGS84	D.Est X	D.Est Y	D.Est Z
1	Fijo (Fase)	1/5	532082.0385 m	-6252649.9550 m	1137294.4795 m	0.0008 m	0.0015 m	0.0007 m

1 - 2023-12-05 11:48:02

Resultados de Ocupación de Punto

Marker Name: 1 Tipo de Receptor / SN: GEOMAX ZENITH40 / 1791850
Tipo de Antena / SN: GMXZENITH40 NONE / -
Inicio de Ocupación: 2023-12-05 11:48:02 Fin de Ocupación: 2023-12-05 12:08:06

Resumen de punto promedio: 1

Promedio ponderado:
Sí
WGS84 Latitud: 10° 20' 24.8627" N D.Est latitud: 0.0007 m
WGS84 Longitud: 85° 08' 09.6601" W D.Est longitud: 0.0008 m
WGS84 Altura.Elíp: 20.9305 m DE Alt: 0.0016 m
WGS84 Cartesiana X: 532082.0385 m D.Est X: 0.0008 m
WGS84 Cartesiana Y: -6252649.9550 m D.Est Y: 0.0015 m
WGS84 Cartesiana Z: 1137294.4795 m D.Est Z: 0.0007 m
X: - D.Est X: -
Coordenada Y: - D.Est Y: -
Altura Elipsoidal: - DE Alt: -
Altura Ortom.: -

Resumen de líneas de base 1

ID- Punto	Referencia	Longitud de Línea Base [m]	3D QC [m]	ΔX	ΔY	ΔZ	X	Y	Z
1							532082.0385 m	-6252649.9550 m	1137294.4795 m
	CHLS	89525.6988 m	0.0034 m	0.0499 m	-0.1333 m	-0.0154 m	532081.9886 m	-6252649.8217 m	1137294.4949 m
	CIQE	77261.0298 m	0.0109 m	-0.1074 m	0.3332 m	-0.2363 m	532082.1459 m	-6252650.2882 m	1137294.7158 m
	LBRA	46118.2964 m	0.0083 m	-0.2630 m	-0.2408 m	0.1138 m	532082.3015 m	-6252649.7142 m	1137294.3657 m
	NYCO	41140.6509 m	0.0102 m	-0.1326 m	-0.0104 m	0.1390 m	532082.1711 m	-6252649.9446 m	1137294.3405 m
	PUNT	51939.3730 m	0.0019 m	0.0000 m	0.0000 m	0.0000 m	532082.0385 m	-6252649.9550 m	1137294.4795 m

Anexo 3. Ejemplo de primera página de reporte de calidad de PIX4Dmapper.

Quality Report



Generated with PIX4Dmapper version 4.7.5

! **Important:** Click on the different icons for:

- ?** Help to analyze the results in the QualityReport
- i** Additional information about the sections

💡 Click [here](#) for additional tips to analyze the QualityReport

Summary **i**

Project	sorgo_v5_F23_nov
Processed	2024-02-15 18:47:04
Camera Model Name(s)	Altum_8.0_2064x1544 (Blue), Altum_8.0_2064x1544 (Green), Altum_8.0_2064x1544 (Red), Altum_8.0_2064x1544 (NIR), Altum_8.0_2064x1544 (Red edge)
Rig name(s)	«Altum»
Average Ground Sampling Distance (GSD)	2.09 cm / 0.82 in
Area Covered	0.018 km ² / 1.7962 ha / 0.01 sq. mi. / 4.4408 acres
Time for Initial Processing (without report)	10m:49s

Quality Check **i**

? Images	median of 10000 keypoints per image	✓
? Dataset	1410 out of 1415 images calibrated (99%), 5 images disabled	✓
? Camera Optimization	0.31% relative difference between initial and optimized internal camera parameters	✓
? Matching	median of 5039.64 matches per calibrated image	✓
? Georeferencing	yes, 3 GCPs (3 3D), mean RMS error = 0.021 m	✓

Anexo 4. Script en lenguaje de programación R para la extracción de datos espectrales para múltiples mosaicos

```
``{r, include=F}
```

```
library(mapview)
```

```
library(raster)
```

```
library(tidyverse)
```

```
library(DataExplorer)
```

```
library(DescTools)
```

```
library(dplyr)
```

```
library(lattice)
```

```
library(rgdal)
```

```
library(gstat)
```

```
library(sp)
```

```
...
```

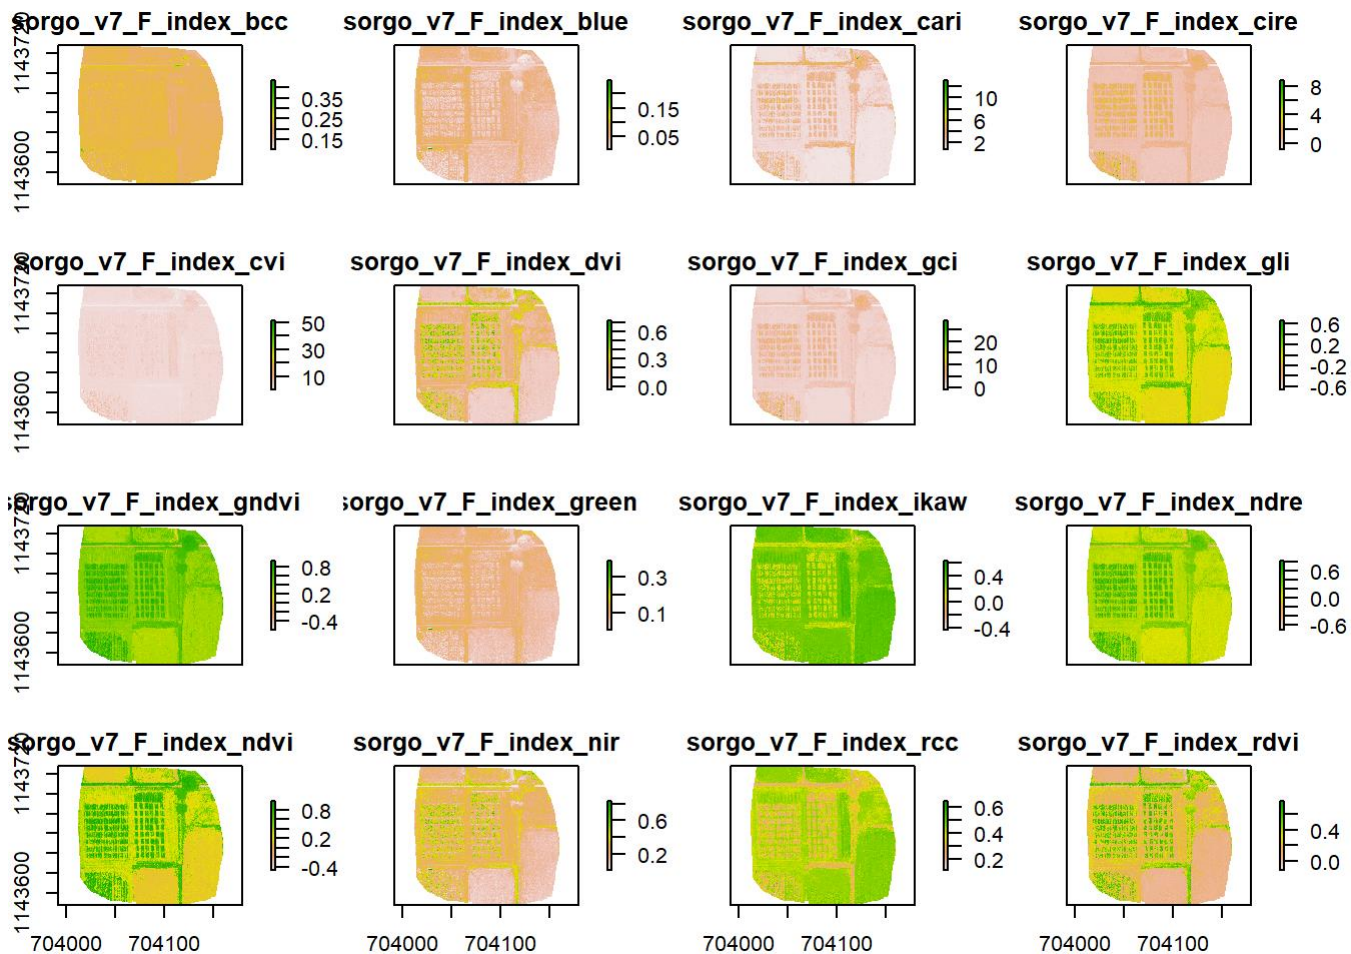
```
#set to directory
```

```
# Loading orthomosaic, Spectral INDEX from PIX4D
```

```
setwd("C:/Users/INTA/Desktop/Tesis/spectral_flight7")
```

```
cov=stack(list.files(pattern='tif'))
```


```
plot(cov) #plot ÍNDICES
```



```
#SE CARGAN LAS PARCELAS EXPERIMENTALES
```

```
parcelas=readOGR(dsn="C:/Users/INTA/Desktop/Tesis/spectral_flight7", layer="plots_rf_f7")
```

```
plot(parcelas, axes=T)
```



VISTA DE LOS VECTORES E ÍNDICES (ASEGURARSE DEL POSICIONAMIENTO ESPACIAL)

```
mapview(parcelas) + mapview(cov)
```



```

cari = mean(sorgo_v7_F_index_cari),
cire = mean(sorgo_v7_F_index_cire),
cvi = mean(sorgo_v7_F_index_cvi),
dvi = mean(sorgo_v7_F_index_dvi),
gci = mean(sorgo_v7_F_index_gci),
gli= mean(sorgo_v7_F_index_gli),
gndvi = mean(sorgo_v7_F_index_gndvi),
green = mean(sorgo_v7_F_index_green),
ikaw = mean(sorgo_v7_F_index_ikaw),
ndre = mean(sorgo_v7_F_index_ndre),
ndvi = mean(sorgo_v7_F_index_ndvi),
nir = mean(sorgo_v7_F_index_nir),
rcc = mean(sorgo_v7_F_index_rcc),
rdvi = mean(sorgo_v7_F_index_rdvi),
red_edge = mean(sorgo_v7_F_index_red_edge),
red = mean(sorgo_v7_F_index_red),
redvi = mean(sorgo_v7_F_index_redvi),
rgri = mean(sorgo_v7_F_index_rgri),
savi= mean(sorgo_v7_F_index_savi),
sr = mean(sorgo_v7_F_index_sr)

```

```
data_espectral3
```

#Unimos los datos promediados a las parcelas originales

```
d_bf_mean=cbind(data_espectral3, parcelas)
```

#exportamos los datos

```
write.table(d_bf_mean, file = "spectralv7_mean.csv", row.names =F, sep="
\t")
```