

UNIVERSIDAD LAICA ELOY ALFARO DE MANABÍ
EXTENSIÓN EL CARMEN
CARRERA DE INGENIERÍA AGROPECUARIA
Creada Ley No 10 – Registro Oficial 313 de Noviembre 13 de 1985

PROYECTO DE INVESTIGACIÓN


TRABAJO EXPERIMENTAL PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO AGROPECUARIO

**“Identificación de deficiencias nutricionales en pasto *Brachiaria* sp.,
mediante fotografía espectral”**

AUTOR: Edu Beбето Pesantez Muñoz

TUTOR: Ing. Francel Xavier López Mejía, PhD.

El Carmen, julio del 2024

 Uleam <small>UNIVERSIDAD LAICA</small> <small>ELOY ALFARO DE MANABÍ</small>	NOMBRE DEL DOCUMENTO:	CÓDIGO: PAT-01-F-010
	CERTIFICADO DE TUTOR(A)	
	PROCEDIMIENTO: TITULACIÓN DE ESTUDIANTES DE GRADO	REVISIÓN: 2
		Página 1 de 78

CERTIFICACIÓN

En calidad de docente tutor(a) de la carrera de Ingeniería Agropecuaria de la Universidad Laica “Eloy Alfaro” de Manabí, CERTIFICO:

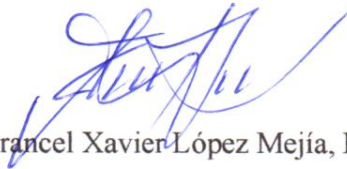
Haber dirigido y revisado el trabajo de titulación, bajo la autoría del estudiante Pesantez Muñoz Edu Beбето, legalmente matriculado en la carrera de Ingeniería Agropecuaria, periodo académico 2023-2024, cumpliendo el total de 384 horas, bajo la opción de titulación de proyecto de investigación, cuyo tema del proyecto es “Enmiendas orgánicas como coadyuvante en la fertilización de pasto *Brachiaria sp.*”.

La presente investigación ha sido desarrollada en apego al cumplimiento de los requisitos académicos exigidos por el Reglamento de Régimen Académico y en concordancia con los lineamientos internos de la opción de titulación en mención, reuniendo y cumpliendo con los méritos académicos, científicos y formales, suficientes para ser sometida a la evaluación del tribunal de titulación que designe la autoridad competente.

Particular que certifico para los fines consiguientes, salvo disposición de Ley en contrario.

El Carmen, 25 de julio de 2024

Lo certifico,



Ing. Francel Xavier López Mejía, PhD.

Docente Tutor

Área: Agricultura, Silvicultura, Pesca y Veterinaria

**UNIVERSIDAD LAICA "ELOY ALFARO" DE MANABÍ
EXTENSIÓN EL CARMEN**

CARRERA DE INGENIERÍA AGROPECUARIA

TÍTULO:

Identificación de deficiencias nutricionales en pasto *Brachiaria sp.* mediante
fotografía espectral

AUTOR: Edu Beбето Pesantez Muñoz

TUTOR: Ing. Francel Xavier López Mejía, PhD.

**TRABAJO EXPERIMENTAL PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO AGROPECUARIO**

TRIBUNAL DE TITULACIÓN

MIEMBRO: Ing. Cobeña Loor Nexar Vismar, Mg. _____

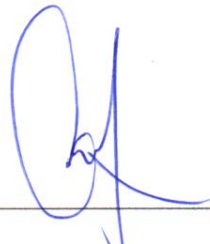
MIEMBRO: Ing. Cedeño Zambrano José Randy, Mg. _____

MIEMBRO: Ing. González Dávila Ricardo Paul, Mg. _____

DECLARACIÓN DE AUTORÍA

Yo, **PESANTEZ MUÑOZ EDU BEBETO** con cédula de ciudadanía 131366482-1, estudiante de la Universidad Laica “Eloy Alfaro” De Manabí, Extensión El Carmen, de la carrera de Ingeniería Agropecuaria, declaro que las opiniones, criterios y resultados encontrados en las aplicaciones de los diferentes instrumentos de investigación que están resumidos en las recomendaciones y conclusiones de la presente investigación con el tema: **“Identificación de deficiencias nutricionales en pasto *Brachiaria* sp., mediante fotografía espectral”**, son información exclusiva de su autor, apoyados por el criterio de profesionales de diferentes índoles, presentados en la bibliografía que fundamenta este trabajo; al mismo tiempo declaro que el patrimonio intelectual del trabajo investigativo pertenece a la Universidad Laica “Eloy Alfaro” de Manabí, Extensión El Carmen.

Atentamente,

A handwritten signature in blue ink, consisting of a large, stylized 'P' followed by a series of loops and a long horizontal stroke extending to the right.

Pesantez Muñoz Edu Beбето

El Carmen, 16 de agosto de 2024

DEDICATORIA

Este trabajo está dedicado a mi familia, quienes me han brindado su amor, apoyo y motivación a lo largo de todo el proceso de elaboración de esta tesis. Su comprensión y paciencia han sido fundamentales para poder culminar esta importante etapa en mi formación profesional. Ustedes han sido un pilar crucial en mi vida y me han motivado a alcanzar esta importante meta. Este logro también les pertenece a ustedes.

AGRADECIMIENTO

En primer lugar, deseo expresar mi más sincero y profundo agradecimiento a mis padres. Su amor incondicional y su constante apoyo han sido la piedra angular sobre la que se han cimentado todos mis logros. Sin su inestimable guía y respaldo, la realización de este trabajo simplemente no habría sido posible.

Asimismo, extiendo mi más sincera gratitud a los distinguidos profesores que han sido parte de mi formación académica. Su orientación experta, su sabiduría y su apasionada entrega a la labor docente han sido una fuente de inspiración constante a lo largo de mi trayectoria de aprendizaje.

De igual manera, me es grato reconocer a mis compañeros de estudio, quienes han sido un invaluable apoyo a lo largo de esta jornada. Juntos hemos enfrentado los desafíos inherentes a la vida académica, y cada uno de ustedes ha enriquecido enormemente mi experiencia de aprendizaje.

Debo también expresar mi más profundo agradecimiento a todos los agricultores y trabajadores del campo cuya ardua labor y dedicación han sido el foco central de este estudio. Su incansable esfuerzo y compromiso con la tierra han sido una constante inspiración para mí.

Por último, pero no menos importante, me permito agradecer a mí mismo por la perseverancia, la determinación y el ímpetu que he volcado en la realización de este trabajo. Este logro es un testimonio fehaciente de mi firme compromiso con el aprendizaje y el crecimiento personal.

ÍNDICE

CERTIFICACIÓN.....	1
DEDICATORIA.....	3
AGRADECIMIENTO.....	5
ÍNDICE DE TABLAS.....	11
ÍNDICE DE ANEXO.....	12
RESUMEN.....	13
ABSTRACT.....	14
INTRODUCCIÓN.....	15
Objetivo General.....	16
Objetivos Específicos.....	16
HIPÓTESIS.....	16
CAPÍTULO I.....	17
1. MARCO TEÓRICO.....	17
1.1. Fotogrametría y Sensores Remotos con Drones.....	17
1.2. Principios de la Fotogrametría con Drones.....	18
1.3. Sensores Remotos Montados en Drones.....	19
1.4. Procesamiento de imágenes espectrales de drones.....	19
1.5. Ventajas y limitaciones de los drones en fotogrametría.....	21
1.5.1. Ventajas.....	21
1.5.2. Limitaciones.....	21

1.6.	Deficiencias Nutricionales en Pastos <i>Brachiaria sp.</i>	22
1.6.1.	Requerimientos nutricionales del pasto <i>Brachiaria</i>	22
1.6.2.	Síntomas visuales de deficiencias nutricionales específicas	23
1.6.3.	Efectos de las deficiencias en el crecimiento y productividad	23
1.7.	Análisis de Imágenes Espectrales para Detección de Deficiencias	24
1.7.1.	Firmas espectrales de la vegetación sana y deficiente.....	24
1.7.2.	Índices de vegetación para cuantificar deficiencias	25
1.7.3.	Técnicas de clasificación supervisada y no supervisada	26
1.7.5.	Validación de resultados con datos de campo	27
1.7.6.	Los datos de campo pueden incluir	27
1.7.7.	Estrategias de fertilización y enmiendas	27
1.7.8.	Monitoreo del estado nutricional post-corrección	28
1.7.9.	Evaluación de la recuperación mediante imágenes espectrales.....	29
1.8.	Aplicaciones Prácticas de la Teledetección en Praderas	30
1.8.1.	Mapeo de la variabilidad nutricional en potreros	30
1.8.2.	Agricultura de precisión para aplicación localizada de insumos.....	30
1.8.3.	Toma de decisiones basada en información espectral	31
1.9.	Revisión de Estudios Previos	31
1.9.1.	Antecedentes de teledetección para identificar deficiencias nutricionales.....	31
1.9.2.	Casos de estudio en pastos o cultivos similares	32
1.9.3.	Lecciones aprendidas y brechas de conocimiento.....	32

1.10.	Fisiología vegetal y nutrición mineral	33
1.10.1.	Roles específicos de macro y micronutrientes en el metabolismo vegetal	33
1.10.3.	Mecanismos de absorción, transporte y asimilación de nutrientes.....	34
1.10.4.	Respuestas fisiológicas ante deficiencias nutricionales específicas	34
1.11.	Características espectrales de la vegetación estresada	34
1.11.1.	Cambios en las firmas espectrales inducidos por diferentes tipos de estrés biótico/abiótico.....	34
1.11.2.	Pigmentos vegetales y su influencia en las propiedades ópticas	35
1.11.3.	Efectos de la estructura celular y contenido de agua en la reflectancia	35
1.12.	Correcciones atmosféricas y de iluminación	35
1.12.1.	Técnicas para compensar efectos atmosféricos en imágenes espectrales.....	35
1.12.2.	Normalización de condiciones de iluminación variables	36
1.12.3.	Importancia de las correcciones para análisis cuantitativos precisos	36
1.14.	Diseño experimental y muestreo	37
1.14.1.	Estrategias de muestreo para generar datos de entrenamiento/validación	37
1.14.2.	Consideraciones sobre tamaño de muestra, réplicas, aleatorización	37
1.14.3.	Técnicas de muestreo adaptadas a restricciones operativas con drones.....	37
1.15.	Transferibilidad de modelos espectrales.....	38
1.15.1.	Desafíos para extrapolar modelos a nuevas áreas/temporadas	38
1.15.2.	Métodos para aumentar la transferibilidad	38
1.15.3.	Necesidad de calibración local y adaptación de modelos.....	39

1.15.4. Requerimiento nutricional de la <i>Brachiaria brizantha</i> cv.	39
CAPITULO II.....	41
2. INVESTIGACIONES EXPERIMENTALES AFINES AL PROYECTO DE INVESTIGACIÓN	41
CAPÍTULO III	43
3. MATERIALES Y MÉTODOS	43
3.1. Localización de la unidad experimental	43
3.2. Caracterizaciones climáticas de la zona	43
3.3. Variables.....	43
3.4. Variables independientes.....	43
3.4.1. Métodos	43
3.4.2. Frecuencia.....	44
3.5. Variables dependientes.....	44
3.6. Instrumentos de medición.....	44
3.6.1. Materiales y equipos de campo	44
3.6.2. Materiales de oficina y muestreo.....	44
3.6.3. Manejo del ensayo	44
Preparación del terreno.....	44
Toma de muestras de suelo iniciales	44
Equipos empleados.....	44
Procesamiento y análisis de datos	45

CAPÍTULO IV	46
4. RESULTADOS Y DISCUSIÓN.....	46
4.1. Análisis de suelo.....	46
4.2. Imágenes RGB.....	48
4.3. Análisis foliar	55
CAPITULO V	58
5. CONCLUSIONES	58
CAPITULO VI.....	59
6. RECOMENDACIONES	59
REFERENCIAS BIBLIOGRÁFICAS	XXXV
ANEXOS.....	LIII

ÍNDICE DE TABLAS

Tabla 1. Requerimiento nutricional de la <i>Brachiaria brizantha</i> cv.	40
Tabla 2. Características agroecológicas de la localidad	43
Tabla 3. Resultados del análisis de suelo realizado en el terreno cultivado.	46
Tabla 4. Resultados del análisis de suelo realizado en el terreno cultivado.	55

ÍNDICE DE ANEXO

Anexo 1. ADEVA de la variable altura de la planta	LIII
Anexo 2. Hojas foliares de la planta de pasto Brachiaria.....	LIII
Anexo 3. Dron Autel Evo 2 Pro 6k	LIV

RESUMEN

El estudio se centra en el uso de drones equipados con cámaras multispectrales para identificar y cuantificar deficiencias nutricionales en pastos *Brachiaria sp.*, en una hacienda de producción de ganado bovino lechero en Santo Domingo de los Tsáchilas, Ecuador. Se empleó un dron Autel Evo 2 Pro 6K para capturar imágenes aéreas de alta resolución que luego fueron analizadas para detectar niveles de nutrientes como nitrógeno, fósforo, potasio y otros. El análisis del suelo reveló deficiencias en ciertos nutrientes, lo que podría limitar el desarrollo y la producción del pasto. La metodología incluyó la toma de imágenes a 150 metros de altura y la validación de resultados mediante datos de campo. Se concluyó que la fotogrametría con drones es una herramienta eficaz para el monitoreo y manejo nutricional de los potreros, permitiendo una intervención oportuna y precisa en la fertilización y enmiendas del suelo. Este enfoque innovador promete mejorar la sostenibilidad y eficiencia de la producción ganadera tropical.

Palabras claves: Drones, Fotogrametría, Deficiencias nutricionales, Pasto *Brachiaria*, Agricultura de precisión.

ABSTRACT

The study focuses on the use of drones equipped with multispectral cameras to identify and quantify nutritional deficiencies in *Brachiaria sp.*, pastures at a dairy cattle production farm in Santo Domingo de los Tsáchilas, Ecuador. An Autel Evo 2 Pro 6K drone was used to capture high-resolution aerial images, which were then analyzed to detect nutrient levels such as nitrogen, phosphorus, potassium, and others. Soil analysis revealed deficiencies in certain nutrients that could limit the development and production of the pasture. The methodology included taking images at 150 meters altitude and validating the results with field data. The study concluded that photogrammetry with drones is an effective tool for monitoring and managing the nutritional status of pastures, enabling timely and precise intervention in fertilization and soil amendments. This innovative approach promises to enhance the sustainability and efficiency of tropical livestock production.

Keywords: Drones, Photogrammetry, Nutritional deficiencies, Brachiaria Grass, Precision agriculture.

INTRODUCCIÓN

El pasto *Brachiaria sp.* un género de gramíneas forrajeras ampliamente utilizado en la ganadería tropical, desempeña un papel crucial en la productividad y sostenibilidad de los sistemas de producción animal. Sin embargo, las deficiencias nutricionales pueden limitar su crecimiento, vigor y calidad nutricional, lo que afecta directamente el rendimiento y la salud del ganado (Louw-Gaume y otros, 2010). En este contexto, la identificación temprana y precisa de estas deficiencias es fundamental para implementar prácticas de manejo adecuadas y maximizar la rentabilidad de las operaciones ganaderas.

Al aprovechar esta tecnología no invasiva y de alta resolución, los productores podrían tomar decisiones informadas y oportunas para mantener la calidad y productividad de sus pasturas, asegurando así la viabilidad económica y ambiental de sus operaciones.

La fotografía espectral, una técnica no destructiva y de alto rendimiento, ha demostrado su potencial para detectar y cuantificar deficiencias nutricionales en cultivos vegetales (Mariotto y otros, 2013). Esta tecnología ha sido ampliamente estudiada en diversos cultivos agrícolas, pero su aplicación en pasturas tropicales, como el género *Brachiaria sp.*, sigue siendo un área de investigación relativamente nueva.

El problema científico radica en la falta de conocimiento sobre la identificación y cuantificación de deficiencias nutricionales específicas en el pasto *Brachiaria sp.*, mediante el uso de la fotografía espectral. Esto representa un vacío en el conocimiento que, de resolverse, podría contribuir significativamente al desarrollo de prácticas sostenibles y eficientes en la producción ganadera tropical (Skerman & Riveros, 1990).

Por lo tanto, el presente estudio tiene como objetivo desarrollar modelos de predicción basados en la firma espectral del pasto *Brachiaria sp.*, para identificar y cuantificar deficiencias nutricionales específicas, como nitrógeno, fósforo, potasio y otros elementos esenciales. Esta información podría ser utilizada por los productores para ajustar los programas de fertilización, optimizar el uso de recursos y minimizar el impacto ambiental (Numata y otros, 2018). Al abordar este problema científico, se espera adquirir conocimientos nuevos y relevantes que contribuyan al manejo sostenible de los sistemas de producción ganadera en regiones tropicales.

Objetivo General

Comprobar la eficiencia en la identificación de trastorno nutricionales en pastos *Brachiaria sp* utilizando fotografías espectrales tomadas por un dron.

Objetivos Específicos

- Evaluar la capacidad de las fotografías espectrales para identificar la deficiencia nutricional en los pastos.
- Identificar los síntomas visuales asociados con deficiencias nutricionales de forma tradicional en los potreros y establecer correlaciones con las imágenes espectrales capturadas por el dron.
- Proponer recomendaciones prácticas para el manejo nutricional de los potreros basadas en los resultados obtenidos con la identificación de deficiencias nutricionales a través de fotografías espectrales con drones.

HIPÓTESIS

Hipótesis nula (H₀): La identificación de deficiencias nutricionales en pastos utilizando fotografías espectrales tomadas por drones no es funcional

Hipótesis alternativa (H_i): La identificación de deficiencias nutricionales en pastos utilizando fotografías espectrales tomadas por drones es significativamente funcional.

CAPÍTULO I

1. MARCO TEÓRICO

Al capturar imágenes en diferentes longitudes de onda del espectro electromagnético, desde el visible hasta el infrarrojo cercano, es posible obtener información valiosa sobre la composición bioquímica y el estado nutricional de las plantas (Gitelson y otros, 1996).

1.1. Fotogrametría y Sensores Remotos con Drones

La fotogrametría con drones ha ganado una gran importancia en los últimos años debido a su capacidad para adquirir datos de alta resolución a bajo costo y de manera eficiente. Los drones, también conocidos como vehículos aéreos no tripulados (UAV, por sus siglas en inglés), se han convertido en una herramienta valiosa para la adquisición de imágenes y datos remotos en diversas áreas, incluyendo la agricultura de precisión, la gestión de recursos naturales y la cartografía (Barreto y otros, 2020).

Según Hassanin y otros. (2019), la fotogrametría con drones se basa en la adquisición de múltiples imágenes superpuestas de una superficie o área de interés desde diferentes ángulos y elevaciones. Estas imágenes se procesan posteriormente mediante técnicas fotogramétricas para generar modelos 3D, ortomosaicos y productos derivados como modelos digitales de elevación (MDE) y modelos digitales de superficie (MDS). "La precisión de estos productos depende de varios factores, como la resolución de la cámara, la altura de vuelo, el solape de imágenes, las condiciones de iluminación y la geometría de adquisición" (Hassanin y otros., 2019, p. 2)

Una de las principales ventajas de los drones es su capacidad para llevar diferentes tipos de sensores, incluyendo cámaras RGB convencionales, cámaras multiespectrales e hiperespectrales, y sensores térmicos o de rayos gamma (Maes & Steppe, 2019). Estos sensores permiten la adquisición de imágenes espectrales que pueden utilizarse para monitorear el estado de la vegetación, detectar estrés hídrico o nutricional, y realizar análisis de cobertura terrestre, entre otras aplicaciones.

Según Maes & Steppe (2019), "las imágenes multiespectrales e hiperespectrales adquiridas por drones tienen el potencial de proporcionar información valiosa sobre el estado fisiológico de las plantas, lo que puede ser útil para la gestión de cultivos y la agricultura de precisión" (p. 4). Estas imágenes pueden procesarse utilizando técnicas de teledetección, como el cálculo de

índices de vegetación y la clasificación de imágenes, para extraer información relevante sobre el estado de la vegetación.

Sin embargo, el uso de drones para fotogrametría y sensores remotos también presenta desafíos y limitaciones. Por ejemplo, la adquisición de datos puede verse afectada por condiciones meteorológicas adversas, restricciones de vuelo en ciertas áreas y requisitos legales y regulatorios (Maes & Steppe, 2019). Además, el procesamiento y análisis de grandes cantidades de datos obtenidos por drones puede ser computacionalmente intensivo y requerir habilidades técnicas específicas.

La fotogrametría y los sensores remotos con drones ofrecen oportunidades emocionantes para la adquisición de datos de alta calidad en diversas aplicaciones, incluyendo la agricultura y la gestión de recursos naturales. Sin embargo, es importante considerar las limitaciones y desafíos asociados con esta tecnología y desarrollar enfoques adecuados para el procesamiento y análisis de los datos obtenidos.

1.2. Principios de la Fotogrametría con Drones

La fotogrametría con drones se basa en el principio de triangulación, que implica la reconstrucción de la geometría tridimensional a partir de múltiples imágenes bidimensionales superpuestas (Siebert & Teizer, 2014). Este proceso se conoce como estructura a partir del movimiento (SfM, por sus siglas en inglés) y se logra mediante técnicas de visión computarizada y análisis de imágenes.

El proceso de adquisición de datos con drones implica planificar un plan de vuelo que cubra el área de interés con un solape adecuado entre las imágenes (generalmente entre 60% y 80%) (Carrivick y otros, 2016). Durante el vuelo, el dron captura imágenes de forma automática y georeferenciada utilizando su sistema de posicionamiento global (GPS) y sensores inerciales.

Después de la adquisición de datos, las imágenes se procesan mediante software fotogramétrico especializado, como Agisoft Photoscan, Pix4D o DroneDeploy. Estos programas utilizan algoritmos de reconocimiento de características y técnicas de ajuste de haces para identificar puntos comunes en las imágenes superpuestas y calcular las coordenadas 3D de estos puntos (Siebert & Teizer, 2014). El resultado final es un modelo 3D denso de la superficie, conocido como nube de puntos, que puede ser utilizado para generar productos derivados como

modelos digitales de elevación (MDE), modelos digitales de superficie (MDS) y ortomosaicos.

1.3. Sensores Remotos Montados en Drones

Los drones ofrecen la capacidad de montar una variedad de sensores remotos, lo que amplía significativamente sus aplicaciones. Además de las cámaras RGB convencionales, los sensores comúnmente utilizados en drones incluyen:

Cámaras multiespectrales: Estas cámaras capturan imágenes en varias bandas estrechas del espectro electromagnético, como el visible, el infrarrojo cercano y el infrarrojo de onda corta (Hassanin y otros, 2019). Estas imágenes permiten el cálculo de índices de vegetación, como el NDVI (Índice de Vegetación de Diferencia Normalizada), que son útiles para monitorear el estado de la vegetación y detectar estrés.

Cámaras hiperespectrales: Estas cámaras capturan imágenes en cientos de bandas estrechas del espectro electromagnético, lo que permite una caracterización espectral detallada de los objetos en la superficie (Adão y otros, 2017). Estas imágenes se utilizan para aplicaciones como la detección de enfermedades en cultivos, la identificación de especies vegetales y la evaluación de la calidad del suelo.

Sensores térmicos: Estos sensores detectan la radiación infrarroja térmica emitida por los objetos en la superficie, lo que permite medir la temperatura de la superficie (Hassan-Esfahani y otros, 2017). Esto es útil para monitorear el estrés hídrico en la vegetación, detectar fugas de calor en edificios y monitorear la actividad volcánica.

Sensores LiDAR: Los sensores LiDAR (Light Detection and Ranging) emiten pulsos de láser y miden el tiempo de retorno de los pulsos reflejados para crear nubes de puntos 3D de alta precisión (Salach y otros, 2018). Estas nubes de puntos se utilizan para cartografía de alta resolución, modelado 3D y monitoreo de cambios en la superficie.

Estos sensores pueden integrarse en plataformas de drones para ampliar las capacidades de adquisición de datos y proporcionar información valiosa para diversas aplicaciones, como la agricultura de precisión, la gestión forestal, la cartografía y la monitorización ambiental.

1.4. Procesamiento de imágenes espectrales de drones

El procesamiento de imágenes espectrales adquiridas por drones implica una serie de pasos

y técnicas para extraer información valiosa de los datos. Según Torres-Sánchez y otros. (2018), el flujo de trabajo típico para el procesamiento de imágenes espectrales de drones incluye:

Correcciones radiométricas: Implica la conversión de los valores digitales de las imágenes a valores de radiancia o reflectancia para corregir los efectos atmosféricos y de iluminación. Esto es esencial para poder comparar los valores espectrales entre diferentes imágenes y fechas (Honkavaara y otros, 2013).

Alineación y ortorrectificación: Este paso consiste en corregir las distorsiones geométricas de las imágenes y alinearlas con un sistema de coordenadas geográficas. Esto se logra mediante técnicas fotogramétricas y el uso de puntos de control terrestre (GCP) (Sanz-Abajnides y otros, 2019).

Generación de ortomosaicos y productos derivados: Las imágenes corregidas y alineadas se combinan en un ortomosaico, que es una imagen georeferenciada libre de distorsiones. A partir de este ortomosaico, se pueden generar otros productos como modelos digitales de superficie (MDS) y modelos digitales de elevación (MDE) (Hassanin y otros, 2019).

Cálculo de índices espectrales: Los índices espectrales, como el NDVI (Índice de Vegetación de Diferencia Normalizada) y el PRI (Índice de Reflectancia Fotoquímica), se calculan a partir de las bandas espectrales y se utilizan para monitorear el estado de la vegetación, detectar estrés y evaluar la productividad (Zarco-Tejada y otros, 2013).

Clasificación de imágenes: Las técnicas de clasificación supervisada y no supervisada se utilizan para segmentar las imágenes en diferentes clases o categorías, como tipos de cultivos, suelos o coberturas terrestres. Esto se hace mediante el análisis de las firmas espectrales de los objetos de interés (Hassanin y otros, 2019).

Análisis cuantitativo y mapeo: Los resultados obtenidos, como índices espectrales, mapas de clasificación y modelos 3D, se analizan cuantitativamente y se presentan en forma de mapas temáticos o productos derivados para su interpretación y toma de decisiones (Sanz-Abajnides y otros, 2019).

El procesamiento de imágenes espectrales de drones puede realizarse mediante software

comercial, como Agisoft Photoscan, Pix4D o DroneDeploy, o mediante herramientas de código abierto como QGIS, R o Python (Torres-Sánchez y otros, 2018). La elección del software y las técnicas específicas dependerá de los objetivos del estudio y los requisitos de precisión y escalabilidad.

1.5. Ventajas y limitaciones de los drones en fotogrametría

El uso de drones en fotogrametría y sensores remotos ofrece numerosas ventajas en comparación con los métodos tradicionales, pero también presenta algunas limitaciones que deben considerarse:

1.5.1. Ventajas

Flexibilidad y accesibilidad: Los drones permiten acceder a áreas remotas o peligrosas de manera segura y rentable (Hassanin y otros, 2019). Además, pueden desplegarse rápidamente y operar en entornos desafiantes.

Resolución espacial y temporal alta: Al volar a bajas altitudes, los drones pueden adquirir imágenes de muy alta resolución espacial (centímetros por píxel) y con una alta frecuencia temporal, lo que permite monitorear cambios rápidos en el terreno (Maes & Steppe, 2019).

Costo-efectividad: Los drones y los sensores asociados son relativamente más asequibles en comparación con los sistemas de teledetección aerotransportados o satelitales (Hassanin y otros, 2019).

Versatilidad de sensores: Los drones pueden llevar una amplia gama de sensores, como cámaras multispectrales, hiperespectrales, térmicas y LiDAR, ampliando sus capacidades de adquisición de datos (Sanz-Abajnides y otros, 2019).

Productos derivados personalizados: Los datos de drones pueden procesarse para generar productos derivados personalizados, como modelos 3D, ortomosaicos, mapas temáticos y modelos digitales de elevación (MDE) (Maes & Steppe, 2019).

1.5.2. Limitaciones

Cobertura espacial limitada: Los drones tienen una autonomía de vuelo y cobertura espacial limitada en comparación con los sistemas aerotransportados o satelitales (Hassanin y

otros, 2019).

Condiciones meteorológicas: Las condiciones meteorológicas adversas, como vientos fuertes, lluvia o niebla, pueden limitar la operación de drones y afectar la calidad de los datos adquiridos (Maes & Steppe, 2019).

Regulaciones y restricciones legales: Existen regulaciones y restricciones legales en la mayoría de los países que limitan el uso de drones en ciertas áreas o condiciones (Hassanin y otros, 2019).

Procesamiento de datos intensivo: El procesamiento de grandes cantidades de datos de alta resolución adquiridos por drones puede ser computacionalmente intensivo y requerir recursos de hardware y software especializados (Sanz-Abajñides y otros, 2019).

Requisitos de experiencia técnica: La operación de drones y el procesamiento de datos fotogramétricos y de teledetección requieren habilidades técnicas y capacitación especializada (Maes & Steppe, 2019).

A pesar de estas limitaciones, los drones han demostrado ser una herramienta poderosa y versátil para la fotogrametría y los sensores remotos en diversos campos, como la agricultura, la gestión forestal, la topografía y la monitorización ambiental. Sin embargo, es importante tener en cuenta estas limitaciones y adoptar prácticas y protocolos adecuados para maximizar los beneficios y minimizar los riesgos asociados con su uso.

1.6. Deficiencias Nutricionales en Pastos *Brachiaria sp.*

1.6.1. Requerimientos nutricionales del pasto *Brachiaria*

El pasto *Brachiaria sp.* es una especie forrajera ampliamente cultivada en regiones tropicales y subtropicales. Para un crecimiento óptimo y una alta productividad, este pasto requiere un suministro adecuado de nutrientes esenciales. Según Rao y otros. (1996), los principales requerimientos nutricionales del pasto *Brachiaria* son:

Nitrógeno (N): Es el nutriente más importante para el crecimiento vegetativo y la producción de biomasa. Las deficiencias de nitrógeno conducen a un crecimiento lento y una coloración amarillenta en las hojas (Rao y otros, 1996).

Fósforo (P): Desempeña un papel crucial en la transferencia de energía, la formación de raíces y el desarrollo reproductivo. La deficiencia de fósforo puede limitar severamente el crecimiento y la producción de semillas (Miles y otros, 2004).

Potasio (K): Es esencial para el metabolismo de carbohidratos, la regulación del agua y la tolerancia al estrés. La deficiencia de potasio puede afectar la resistencia a enfermedades y la calidad nutricional del forraje (Rao y otros, 1996).

Además, el pasto *Brachiaria* también requiere niveles adecuados de otros nutrientes como calcio, magnesio, azufre y micronutrientes como hierro, manganeso, cobre y zinc (Miles y otros, 2004).

1.6.2. Síntomas visuales de deficiencias nutricionales específicas

Los síntomas visuales de deficiencias nutricionales en el pasto *Brachiaria* pueden variar según el nutriente específico y la severidad de la deficiencia. Algunos de los síntomas más comunes son:

Deficiencia de nitrógeno: Las hojas adquieren una coloración amarillenta o verde pálido, comenzando desde las hojas más viejas hacia las más jóvenes. El crecimiento se ralentiza y las plantas se ven raquílicas (Rao y otros, 1996).

Deficiencia de fósforo: Las hojas presentan una coloración verde oscura o rojiza, y pueden aparecer manchas o decoloraciones irregulares. El crecimiento se retarda y las plantas presentan un sistema radicular poco desarrollado (Miles y otros, 2004).

Deficiencia de potasio: Las hojas presentan una coloración amarillenta o bronceada, comenzando desde los bordes y avanzando hacia el centro. Las puntas de las hojas pueden secarse y aparecer quemaduras (Rao y otros, 1996).

Deficiencia de magnesio: Las hojas desarrollan una clorosis internerval, es decir, las áreas entre las nervaduras principales se vuelven amarillentas o blanquecinas, mientras que las nervaduras permanecen verdes (Miles y otros, 2004).

1.6.3. Efectos de las deficiencias en el crecimiento y productividad

Las deficiencias nutricionales en el pasto *Brachiaria* pueden tener efectos significativos en

su crecimiento y productividad, lo que a su vez puede afectar la calidad del forraje y el rendimiento de los sistemas ganaderos. Según Rao y otros. (1996) y Miles y otros. (2004), algunos de estos efectos incluyen:

Reducción en la producción de biomasa: Las deficiencias nutricionales pueden limitar el crecimiento y la acumulación de biomasa del pasto, lo que resulta en una menor disponibilidad de forraje.

Disminución de la calidad nutricional: Las deficiencias pueden afectar la concentración de proteínas, carbohidratos y otros compuestos esenciales en el forraje, reduciendo su valor nutricional para el ganado.

Menor persistencia y vigor: Las plantas deficientes son más susceptibles al estrés ambiental, plagas y enfermedades, lo que puede conducir a una menor persistencia y vigor del pasto en el tiempo.

Baja eficiencia en el uso de recursos: Las deficiencias nutricionales pueden reducir la eficiencia con la que el pasto utiliza los recursos disponibles, como el agua y la luz solar, para producir biomasa.

Disminución de la capacidad de rebrote: Después del pastoreo o corte, las plantas deficientes pueden tener una capacidad reducida para rebrotar y recuperarse, lo que afecta la persistencia y productividad del pastizal.

Por lo tanto, mantener un suministro adecuado de nutrientes y evitar deficiencias nutricionales es fundamental para garantizar un crecimiento óptimo, una alta productividad y una calidad nutricional adecuada del pasto *Brachiaria*, lo que a su vez contribuye a la sostenibilidad y rentabilidad de los sistemas ganaderos.

1.7. Análisis de Imágenes Espectrales para Detección de Deficiencias

1.7.1. Firmas espectrales de la vegetación sana y deficiente

Las firmas espectrales de la vegetación representan la respuesta de la misma a diferentes longitudes de onda del espectro electromagnético. Estas firmas espectrales varían dependiendo del estado de salud y las condiciones nutricionales de las plantas. Según Abdel-Rahman y otros. (2017), las diferencias en las firmas espectrales entre la vegetación sana y deficiente se deben

principalmente a cambios en la concentración de pigmentos fotosintéticos, como la clorofila, y en la estructura interna de las hojas.

La vegetación sana generalmente presenta una alta reflectancia en la región del infrarrojo cercano (700-1300 nm) y una baja reflectancia en la región del visible (400-700 nm), lo que se conoce como el "pico de reflectancia de la vegetación" (Gitelson y otros, 2003). Por otro lado, la vegetación con deficiencias nutricionales suele tener una menor reflectancia en el infrarrojo cercano y una mayor reflectancia en el visible, especialmente en las regiones del rojo y azul, debido a la disminución de la concentración de clorofila y otros pigmentos (Sims & Gamon, 2002).

Además, las deficiencias nutricionales específicas pueden causar cambios característicos en las firmas espectrales. Por ejemplo, la deficiencia de nitrógeno puede provocar una disminución en la reflectancia en la región del verde (550 nm) y un aumento en la región del rojo (670 nm), mientras que la deficiencia de hierro puede resultar en un aumento en la reflectancia en la región del verde y una disminución en el infrarrojo cercano (Abdel-Rahman y otros, 2017).

1.7.2. Índices de vegetación para cuantificar deficiencias

Los índices de vegetación son combinaciones matemáticas de diferentes bandas espectrales que se utilizan para cuantificar las características de la vegetación, incluyendo la detección de deficiencias nutricionales. Algunos de los índices más comunes utilizados para este propósito son:

Índice de Vegetación de Diferencia Normalizada (NDVI): Este índice utiliza las bandas del rojo y del infrarrojo cercano y es sensible a la cantidad de clorofila presente en las hojas. Una disminución en el NDVI puede indicar deficiencias nutricionales o estrés en la vegetación (Rouse y otros, 1974).

Índice de Vegetación Ajustado al Suelo (SAVI): Este índice es una modificación del NDVI que reduce la influencia del suelo en la señal espectral, lo que lo hace útil en áreas con una cobertura vegetal dispersa o irregular (Huete, 1988).

Índice de Reflectancia Fotoquímica (PRI): Este índice se basa en las bandas del verde y del rojo y es sensible a los cambios en la eficiencia del uso de la luz por parte de las plantas, lo que puede ser un indicador temprano de deficiencias nutricionales (Gamon y otros, 1992).

Índice de Clorofila (CI): Este índice utiliza las bandas del rojo, rojo cercano y rojo lejano para estimar la concentración de clorofila en las hojas, lo que puede ser útil para detectar deficiencias de nitrógeno (Gitelson y otros, 2003).

Estos índices se calculan a partir de las imágenes espectrales y pueden ser mapeados y analizados para identificar áreas con deficiencias nutricionales o estrés en la vegetación.

1.7.3. Técnicas de clasificación supervisada y no supervisada

La clasificación de imágenes espectrales es un proceso fundamental para la detección de deficiencias nutricionales en la vegetación. Existen dos enfoques principales: la clasificación supervisada y la no supervisada.

Clasificación supervisada: En este enfoque, se seleccionan muestras o áreas de entrenamiento representativas de las diferentes clases o categorías de interés (por ejemplo, vegetación sana, deficiencia de nitrógeno, deficiencia de fósforo, etc.). Estas muestras se utilizan para "entrenar" un algoritmo de clasificación, como la máxima verosimilitud o las máquinas de vectores de soporte (SVM), para reconocer patrones espectrales similares en el resto de la imagen (Mountrakis y otros, 2011).

Clasificación no supervisada: En este caso, no se proporcionan muestras de entrenamiento previas. En su lugar, los algoritmos de agrupamiento, como K-medias o ISODATA, analizan los valores espectrales de los píxeles de la imagen y los agrupan en clases espectrales basándose en su similitud (Mountrakis y otros, 2011). Posteriormente, estas clases espectrales deben ser asignadas a clases de interés, como vegetación sana o deficiente, mediante la interpretación de expertos o el uso de datos de campo.

Ambos enfoques tienen ventajas y desventajas. La clasificación supervisada suele ser más precisa si se dispone de muestras de entrenamiento adecuadas, pero requiere conocimiento previo de las clases de interés. La clasificación no supervisada puede ser útil cuando no se tiene información previa sobre las clases, pero puede requerir más interpretación manual y validación (Mountrakis y otros, 2011).

1.7.5. Validación de resultados con datos de campo

La validación de los resultados obtenidos a partir del análisis de imágenes espectrales es crucial para garantizar la precisión y confiabilidad de la detección de deficiencias nutricionales. Esta validación se realiza mediante la recopilación de datos de campo que puedan ser comparados con los resultados de la clasificación de imágenes.

1.7.6. Los datos de campo pueden incluir

Mediciones de reflectancia espectral in situ: Se utilizan espectroradiómetros de campo para medir la reflectancia espectral de muestras de vegetación con diferentes niveles de deficiencia nutricional. Estas mediciones se comparan con las firmas espectrales obtenidas de las imágenes (Serbin y otros, 2015).

Evaluaciones visuales: Se realizan evaluaciones visuales en campo para identificar síntomas de deficiencias nutricionales en la vegetación y registrar su ubicación y severidad. Estos datos se utilizan para comparar y validar los resultados de la clasificación de imágenes (Defoor y otros, 2017).

Análisis de tejidos vegetales: Se recolectan muestras de tejido vegetal (hojas, tallos, etc.) y se analizan en laboratorio para determinar la concentración de nutrientes. Estos datos se correlacionan con los resultados de las imágenes espectrales (Villalobos & Ritchie, 2018).

Datos de rendimiento y productividad: Se registran datos de rendimiento y productividad en áreas con diferentes niveles de deficiencia nutricional, lo que permite evaluar el impacto de las deficiencias y validar la precisión de la detección mediante imágenes espectrales (Burai y otros, 2015).

La validación de resultados es esencial para ajustar y mejorar los modelos y algoritmos utilizados en el análisis de imágenes espectrales, así como para cuantificar la precisión y los errores asociados a la detección de deficiencias nutricionales.

1.7.7. Estrategias de fertilización y enmiendas

Una vez identificadas las deficiencias nutricionales en los pastos mediante el análisis de imágenes espectrales, es necesario implementar estrategias adecuadas de fertilización y enmiendas para corregirlas. Según Rao y otros. (1996), algunas de las estrategias comunes

incluyen:

- **Fertilización inorgánica:** La aplicación de fertilizantes inorgánicos como urea, superfosfato triple y cloruro de potasio puede ser efectiva para corregir deficiencias de nitrógeno, fósforo y potasio, respectivamente. Es importante determinar las dosis adecuadas basadas en pruebas de suelo y requerimientos específicos del pasto.
- **Enmiendas orgánicas:** El uso de estiércol, compost o abonos orgánicos puede mejorar la fertilidad del suelo y proporcionar nutrientes de manera más equilibrada (Rao y otros, 1996). Estos materiales también pueden mejorar la estructura del suelo y la retención de agua.
- **Encalado:** En suelos ácidos, la aplicación de enmiendas calizas puede ser necesaria para corregir la acidez y mejorar la disponibilidad de nutrientes como calcio, magnesio y fósforo (Rao y otros, 1996).
- **Inoculación con microorganismos:** La inoculación de las semillas o el suelo con bacterias fijadoras de nitrógeno o hongos micorrízicos puede mejorar la absorción de nutrientes y la tolerancia al estrés en los pastos (Rao y otros, 1996).
- **Manejo de la fertilización sitio-específica:** Utilizando mapas de deficiencias nutricionales obtenidos a partir de imágenes espectrales, es posible aplicar fertilizantes y enmiendas de manera variable en función de los requerimientos específicos de cada zona del potrero (Rao y otros, 1996).

1.7.8. Monitoreo del estado nutricional post-corrección

Después de implementar las estrategias de corrección de deficiencias nutricionales, es fundamental monitorear el estado nutricional de los pastos para evaluar la efectividad de las medidas tomadas. Algunas técnicas comúnmente utilizadas incluyen:

- **Análisis de tejido vegetal:** El análisis de muestras de hojas, tallos y raíces en laboratorio puede proporcionar información precisa sobre los niveles de nutrientes en la planta y ayudar a ajustar las tasas de fertilización (Serrano y otros, 2018).
- **Evaluaciones visuales:** La observación periódica de los síntomas visuales de deficiencias nutricionales en campo puede indicar si las correcciones están surtiendo efecto o si es necesario realizar ajustes (Serrano y otros, 2018).
- **Imágenes espectrales y análisis de índices de vegetación:** La adquisición de

nuevas imágenes espectrales después de las correcciones y el cálculo de índices de vegetación como el NDVI, SAVI o PRI pueden proporcionar información valiosa sobre la recuperación de la vegetación y la respuesta a las enmiendas aplicadas (Serrano y otros, 2018).

1.7.9. Evaluación de la recuperación mediante imágenes espectrales

Las imágenes espectrales obtenidas por drones o sensores remotos pueden ser una herramienta poderosa para evaluar la recuperación de los pastos después de las correcciones de deficiencias nutricionales. Algunas de las técnicas que se pueden utilizar incluyen:

- **Comparación de firmas espectrales:** Las firmas espectrales de las áreas tratadas pueden compararse con las firmas espectrales de áreas sanas o con las firmas espectrales antes de las correcciones para evaluar los cambios en la respuesta espectral de la vegetación (Skidmore y otros, 2010).
- **Análisis de cambios en índices de vegetación:** Los cambios en los valores de índices de vegetación como el NDVI, SAVI o PRI entre las imágenes pre-corrección y post-corrección pueden cuantificar la recuperación de la vegetación y la efectividad de las enmiendas aplicadas (Tilly y otros, 2015).
- **Mapeo de la recuperación:** Mediante técnicas de clasificación de imágenes, es posible mapear las áreas que han mostrado una recuperación exitosa y aquellas que aún presentan deficiencias nutricionales, lo que permite ajustar las estrategias de manejo de manera localizada (Skidmore y otros, 2010).
- **Modelado de la productividad:** Los datos espectrales pueden combinarse con modelos de productividad primaria para estimar el impacto de las deficiencias nutricionales y las correcciones en el rendimiento y la calidad del forraje (Tilly y otros, 2015).

La integración de imágenes espectrales y técnicas de teledetección en el monitoreo y evaluación de la recuperación de pastos después de la corrección de deficiencias nutricionales puede proporcionar información valiosa para optimizar las prácticas de manejo y maximizar la productividad y sostenibilidad de los sistemas ganaderos (Serrano y otros, 2018).

1.8. Aplicaciones Prácticas de la Teledetección en Praderas

1.8.1. Mapeo de la variabilidad nutricional en potreros

Una de las aplicaciones clave de la teledetección en praderas es el mapeo de la variabilidad nutricional dentro de los potreros. Mediante el análisis de imágenes espectrales, es posible identificar y mapear áreas con diferentes niveles de deficiencias nutricionales. Según Serrano y otros. (2018), esto se logra a través de los siguientes pasos:

1. Adquisición de imágenes espectrales de alta resolución utilizando drones o sensores aerotransportados.
2. Cálculo de índices de vegetación como el NDVI, SAVI o PRI para estimar el estado nutricional de la vegetación.
3. Aplicación de técnicas de clasificación supervisada o no supervisada para segmentar las áreas con diferentes niveles de deficiencias.
4. Generación de mapas temáticos que muestren la distribución espacial de la variabilidad nutricional dentro del potrero.

Estos mapas brindan información valiosa para comprender la dinámica espacial de las deficiencias nutricionales y pueden ser utilizados como insumos para la toma de decisiones de manejo.

1.8.2. Agricultura de precisión para aplicación localizada de insumos

Los mapas de variabilidad nutricional obtenidos mediante teledetección pueden ser utilizados para implementar estrategias de agricultura de precisión en praderas. Esto implica la aplicación localizada y específica de fertilizantes, enmiendas y otros insumos en función de los requerimientos nutricionales de cada zona del potrero (Schellberg y otros, 2008).

Algunas de las ventajas de esta aproximación incluyen:

1. Optimización del uso de insumos, reduciendo el desperdicio y los costos asociados.
2. Mejora en la eficiencia de la fertilización y corrección de deficiencias.
3. Minimización del impacto ambiental al evitar la aplicación excesiva de fertilizantes.
4. Incremento en la productividad y calidad del forraje al satisfacer los requerimientos nutricionales de manera sitio-específica.

La integración de la información espectral con sistemas de posicionamiento global (GPS) y equipos de aplicación variable permite la fertilización y enmienda precisa de áreas específicas dentro de los potreros.

1.8.3. Toma de decisiones basada en información espectral

Además del mapeo de deficiencias y la agricultura de precisión, la información espectral obtenida mediante teledetección puede ser utilizada para respaldar una amplia gama de decisiones de manejo en praderas. Según Skidmore y otros. (2010), algunas aplicaciones incluyen:

1. Evaluación del impacto de las prácticas de manejo, como el pastoreo, la quema o la aplicación de enmiendas, en el estado nutricional de los pastos.
2. Monitoreo de la recuperación de áreas degradadas o afectadas por sequías, incendios o plagas.
3. Estimación de la productividad primaria y la disponibilidad de forraje en diferentes áreas de la pradera.
4. Planificación de estrategias de rotación de potreros y carga animal óptima basada en el estado nutricional de los pastos.
5. Identificación de áreas prioritarias para la implementación de prácticas de conservación de suelos y agua.

La información espectral, combinada con datos ambientales, edáficos y de manejo, puede ser integrada en sistemas de soporte de decisiones para optimizar la gestión de praderas y maximizar la productividad y sostenibilidad de los sistemas ganaderos.

1.9. Revisión de Estudios Previos

1.9.1. Antecedentes de teledetección para identificar deficiencias nutricionales

La utilización de la teledetección para identificar deficiencias nutricionales en la vegetación ha sido objeto de investigación durante varias décadas. Uno de los primeros estudios en este campo fue el realizado por (Blackmer y otros, 1994), quienes demostraron la capacidad de las imágenes aéreas de video para detectar deficiencias de nitrógeno en el cultivo de maíz.

Posteriormente, con el advenimiento de sensores hiperspectrales, se abrieron nuevas

oportunidades para el mapeo de deficiencias nutricionales. Trabajos como el de Mutanga & Skidmore (2007) exploraron el uso de datos hiperespectrales para discriminar deficiencias de nitrógeno y fósforo en cultivos de maíz y trigo.

En cuanto a las aplicaciones en pastos, Kawamura y otros. (2011) utilizaron imágenes hiperespectrales aerotransportadas para mapear deficiencias de nitrógeno y fósforo en praderas de pastoreo en Nueva Zelanda. Sus resultados demostraron la viabilidad de esta técnica para el monitoreo del estado nutricional de los pastos.

1.9.2. Casos de estudio en pastos o cultivos similares

Varios estudios han abordado la identificación de deficiencias nutricionales en pastos y cultivos forrajeros utilizando diferentes enfoques de teledetección. Por ejemplo, Tian y otros. (2011) evaluaron el uso de imágenes multiespectrales de satélite para detectar deficiencias de nitrógeno en praderas de Alfalfa en China, obteniendo resultados prometedores.

En un estudio más reciente, Serrano y otros. (2018) demostraron la eficacia de las imágenes espectrales adquiridas por drones y el análisis de índices de vegetación para identificar deficiencias nutricionales en pastos de *Brachiaria* en Portugal.

Otro caso relevante es el trabajo de Villalobos & Ritchie (2018), quienes utilizaron imágenes hiperespectrales de campo para evaluar el efecto de deficiencias nutricionales en la reflectancia espectral y el rendimiento de biomasa de híbridos de *Brachiaria* en Colombia.

1.9.3. Lecciones aprendidas y brechas de conocimiento

A partir de los estudios previos, se pueden resaltar algunas lecciones aprendidas y brechas de conocimiento en torno a la identificación de deficiencias nutricionales mediante teledetección:

1. La selección adecuada de índices de vegetación y técnicas de análisis de imágenes es crucial para una detección precisa de deficiencias nutricionales (Serrano y otros, 2018).
2. Las imágenes hiperespectrales ofrecen una mayor capacidad de discriminación de deficiencias específicas en comparación con las imágenes multiespectrales, pero su mayor costo y complejidad de procesamiento pueden ser limitantes (Mutanga &

Skidmore, 2007).

3. Los enfoques de teledetección proximal, como las imágenes de drones, pueden proporcionar información más detallada y a una resolución espacial más alta que los sensores aerotransportados o satelitales (Serrano y otros, 2018).
4. Existe una necesidad de más investigación sobre la transferibilidad de modelos y algoritmos de detección de deficiencias entre diferentes especies de pastos, regiones y condiciones ambientales (Villalobos & Ritchie, Efecto de la deficiencia nutricional en la reflectancia espectral y el rendimiento de biomasa de *Brachiaria* híbridos, 2018).
5. La integración de datos espectrales con información auxiliar, como propiedades del suelo y prácticas de manejo, puede mejorar la precisión y la interpretación de los resultados (Kawamura y otros, 2011).
6. Se requiere más investigación sobre la aplicación práctica de la información espectral para la toma de decisiones y la implementación de estrategias de manejo nutricional en praderas (Skidmore y otros, 2010).

En general, la teledetección ha demostrado su potencial para identificar deficiencias nutricionales en pastos y cultivos similares, pero aún existen oportunidades para mejorar las técnicas, ampliar las aplicaciones y abordar brechas de conocimiento específicas.

1.10. Fisiología vegetal y nutrición mineral

1.10.1. Roles específicos de macro y micronutrientes en el metabolismo vegetal

Según Marschner (2012), los macronutrientes nitrógeno (N), fósforo (P) y potasio (K) cumplen roles cruciales como componentes estructurales y funcionales en las plantas. El N es parte integral de las clorofilas, aminoácidos y ácidos nucleicos (Hawkesford y otros, 2012). El P forma parte de moléculas energéticas como el ATP y de los ácidos nucleicos (Vance y otros, 2003). El K regula procesos como la turgencia celular y el balance hídrico (Anschütz et al., 2014). Los micronutrientes como hierro (Fe), manganeso (Mn), boro (B), zinc (Zn) y cobre (Cu) actúan como cofactores enzimáticos y participan en procesos de transferencia de electrones, integridad de membranas, formación de clorofila y metabolismo de carbohidratos (Hansch & Mendel, 2009).

1.10.3. Mecanismos de absorción, transporte y asimilación de nutrientes

La absorción de nutrientes ocurre principalmente por las raíces a través de flujos de masa y difusión (Barber, 1995). Algunos nutrientes requieren transportadores específicos en las membranas (Tsay y otros, 2007). Posteriormente, los nutrientes se movilizan vía xilema y floema, asociados a complejos orgánicos o iones inorgánicos, dependiendo de la tasa de transpiración y fuentes/sumideros metabólicos (Tegeder & Masclaux-Daubresse, 2018). La asimilación involucra transformaciones enzimáticas para incorporar los nutrientes en moléculas orgánicas esenciales (Hawkesford y otros, 2012).

1.10.4. Respuestas fisiológicas ante deficiencias nutricionales específicas

Las deficiencias inducen cambios metabólicos compensatorios como disminución de la fotosíntesis, alteraciones en el balance de fitohormonas, senescencia acelerada, reducción del crecimiento radicular/foliar, entre otros (Hermans y otros., 2006; Nath y otros., 2016). Por ejemplo, la deficiencia de N limita la síntesis de clorofila (Kalaji y otros, 2017), mientras que la de P afecta la formación de membranas y el almacenamiento/transferencia de energía (Hernández & Munné-Bosch, 2015). Deficiencias de K provocan cierre estomático y deshidratación (Anschütz y otros, 2014). Deficiencias de Fe y Mn alteran reacciones redox en cloroplastos y mitocondrias (Hansch & Mendel, 2009). Estos síntomas pueden ser monitoreados mediante teledetección (Gitelson y otros., 2003).

1.11. Características espectrales de la vegetación estresada

1.11.1. Cambios en las firmas espectrales inducidos por diferentes tipos de estrés biótico/abiótico

Los estreses bióticos como plagas, enfermedades y herbivoría, así como los estreses abióticos como sequía, salinidad, radiación o deficiencias nutricionales, provocan alteraciones en la firma espectral de la vegetación (Behmann y otros, 2014). Estas respuestas espectrales permiten diferenciar los tipos de estrés basándose en patrones específicos.

Por ejemplo, el estrés por sequía disminuye la reflectancia en el infrarrojo cercano debido a la reducción del contenido de agua en las hojas (Peñuelas y otros, 1993). El ataque de insectos masticadores aumenta la reflectancia visible al disminuir los pigmentos (Mirik y otros, 2006). Las deficiencias nutricionales como nitrógeno y hierro disminuyen la reflectancia en la región verde y rojo-borde, respectivamente (Govindaraju, 1994; Slaughter y otros, 2008).

1.11.2. Pigmentos vegetales y su influencia en las propiedades ópticas

Los principales pigmentos foliares como clorofilas, carotenoides, antocianinas y compuestos fenólicos, absorben y transmiten luz de forma selectiva en distintas regiones del espectro (Blackburn, 2007). Por ejemplo, las clorofilas absorben fuertemente en las regiones azul y rojo, mientras que los carotenoides lo hacen en la región azul-verde.

Las variaciones en el contenido y composición de estos pigmentos como respuesta a estreses, modifican la reflectancia visible e infrarrojo cercano. Un decremento en clorofilas aumenta la reflectancia roja, mientras que mayores contenidos de carotenoides incrementan la reflectancia verde (Sims & Gamon, 2002).

1.11.3. Efectos de la estructura celular y contenido de agua en la reflectancia

La estructura interna de las hojas, como el arreglo de las células del parénquima esponjoso y empalizada, la superficie cuticular y el espaciado intercelular, afectan la reflectancia en el infrarrojo cercano (Jacquemoud & Ustin, 2001). Las hojas con tejidos esponjosos y amplios espacios intercelulares tienden a reflejar más en esta región.

Por otro lado, el contenido de agua es un factor clave que determina la reflectancia en el infrarrojo de onda corta (1300-2500 nm). El agua absorbe fuertemente en ciertas bandas de esta región, por lo que disminuciones en su contenido incrementan notablemente la reflectancia (Ceccato y otros, 2001).

Por tanto, la combinación de información sobre pigmentos, estructura interna y contenido hídrico, obtenida de diferentes regiones espectrales, permite caracterizar con mayor precisión el estado fisiológico de la vegetación.

1.12. Correcciones atmosféricas y de iluminación

1.12.1. Técnicas para compensar efectos atmosféricos en imágenes espectrales

Las imágenes capturadas desde plataformas aéreas como drones son afectadas por la dispersión y absorción atmosférica, lo cual distorsiona las firmas espectrales de los objetivos. Existen diferentes métodos para corregir estos efectos:

Modelos de transferencia radiactiva: "Calculan la radiancia en el sensor a partir de la reflectancia de superficie y las propiedades atmosféricas. Ejemplos son MODTRAN, 6S y

ATCOR" (Adler-Golden y otros, 1999, p.1)

Método empírico de línea: Relaciona valores de radiancia/reflectancia imagen con mediciones in situ para derivar factores de corrección.

Corrección basada en objetivos oscuros: "Identifica píxeles sombríos para estimar dispersión atmosférica aditiva" (Ediriwickrema & Khorram, 1997, p. 1020).

Correcciones de vapor de agua, ozono, aerosoles: "Usan bandas de absorción específicas para cuantificar estos componentes" (Richter, 1996, p. 678).

1.12.2. Normalización de condiciones de iluminación variables

Las condiciones de iluminación como ángulo solar, sombras de nubes, varían espacial y temporalmente, afectando los valores de reflectancia. "Técnicas como BRDF, C-Corrección, Nadir-Normalización se emplean para normalizar estos efectos direccionales y obtener datos comparables" (Riaño y otros, 2003, p. 1057; Young y otros, 1997, p. 2).

1.12.3. Importancia de las correcciones para análisis cuantitativos precisos

Las correcciones atmosféricas y de iluminación son cruciales para extraer información biofísica confiable sobre la vegetación. Eliminan sesgos que pueden enmascarar diferencias reales en las firmas espectrales, causando errores en la interpretación del estado fisiológico.

Índices espectrales usados para cuantificar clorofila, contenido de agua, biomasa, etc. son muy sensibles a estas perturbaciones. Aplicar correcciones apropiadas permite establecer "relaciones empíricas y modelos de transferencia radiactiva sólidos y transferibles entre diferentes sitios y fechas" (Adler-Golden y otros, 1999, p. 3).

Incluso leves variaciones no corregidas pueden propagar errores significativos en aplicaciones de agricultura de precisión donde se requieren mediciones cuantitativas precisas a nivel de campo o parcela individual. Por lo tanto, las correcciones atmosféricas e iluminación son un paso obligado previo al análisis cuantitativo de imágenes espectrales.

1.14. Diseño experimental y muestreo

1.14.1. Estrategias de muestreo para generar datos de entrenamiento/validación

Para obtener datos de entrenamiento y validación robustos en aplicaciones de teledetección, se emplean diferentes estrategias de muestreo en campo:

- 1. Muestreo aleatorio estratificado:** Divide el área de estudio en estratos homogéneos y toma muestras aleatorias dentro de cada estrato (Congalton & Green, 2009). Asegura representatividad de todas las condiciones.
- 2. Muestreo sistemático no alineado:** Establece una cuadrícula de puntos de muestreo con un inicio aleatorio (Zillmann y otros, 2015). Evita sesgos direccionales.
- 3. Muestreo dirigido:** Identifica áreas de interés utilizando información auxiliar y concentra el muestreo en esas ubicaciones (Muñoz-Huerta y otros, 2013). Útil para categorías de interés escasas.

1.14.2. Consideraciones sobre tamaño de muestra, réplicas, aleatorización

El tamaño de la muestra debe ser suficiente para capturar la variabilidad y construir modelos estadísticos robustos. Congalton & Green (2009) recomiendan al menos 50 muestras por clase en problemas de clasificación.

Múltiples réplicas en cada punto de muestreo permiten caracterizar la variabilidad dentro de las clases. La aleatorización en la selección de puntos de muestreo evita sesgos espaciales y temporales (Foody, 2009).

1.14.3. Técnicas de muestreo adaptadas a restricciones operativas con drones

Los vuelos con drones imponen restricciones de tiempo y cobertura espacial. Algunas técnicas útiles son:

- 1. Muestreo por transectos:** Toma de muestras a lo largo de líneas de vuelo predefinidas (Michez y otros, 2016). Optimiza el uso de la autonomía del dron.
- 2. Muestreo en clusters espaciales:** Agrupa muestras cercanas para mayor eficiencia operativa (Qixing & Jide, 2019). Reduce tiempos de tránsito innecesarios.
- 3. Muestreo temporal sincronizado:** Programa los vuelos y muestreo de campo para

coincidir con condiciones atmosféricas y de iluminación óptimas (Arroyo-Mora y otros, 2019).

Las técnicas de muestreo deben balancear la representatividad estadística con las limitaciones prácticas impuestas por los vuelos de dron.

1.15. Transferibilidad de modelos espectrales

1.15.1. Desafíos para extrapolar modelos a nuevas áreas/temporadas

La transferibilidad de los modelos espectrales desarrollados para una región o periodo de tiempo determinado a nuevas áreas o temporadas se ve comprometida debido a diferencias en:

1. Condiciones atmosféricas: "La atmósfera local (como las condiciones de iluminación y nubosidad) puede cambiar las firmas espectrales registradas" (Dor y otros, 2003, p. 412).
2. Propiedades del objetivo: Las características espectrales del objetivo, "como el contenido de pigmentos foliares, estructura celular y propiedades ópticas de la vegetación, dependen de la fase fenológica y las condiciones de crecimiento" (Atzberger y otros, 2010, p. 124).
3. Procesamiento de imágenes: El procesamiento para la adquisición y corrección de las imágenes espectrales implica decisiones "como ángulo de observación, tiempo de toma, tipo de correcciones aplicadas, que inciden en las firmas espectrales finales" (Hanus y otros, 2021, p. 3).

1.15.2. Métodos para aumentar la transferibilidad

Existen diferentes técnicas para extender la aplicabilidad de los modelos espectrales en distintas condiciones

1. Estrategias de normalización: "Asegurar que las imágenes sean tomadas cerca del mediodía solar, así como aplicar correcciones atmosféricas y de calibración permiten homogeneizar las condiciones de adquisición" (Miura y otros, 2008, p. 1031).
2. Estrategias de agrupamiento: "Realizar agrupamientos de las firmas espectrales registradas permite identificar patrones comunes" (Dor y otros, 2003, p. 414).

3. Mejores prácticas de adquisición: Como "evitar la captura con ángulo cenital próximo a 90°, o en condiciones atmosféricas adversas" (Somers y otros, 2011, p. 216).
4. Análisis retrospectivo: Algunas perturbaciones "se identifican a posteriori mediante procesamiento adicional, permitiendo descartar datos degradados" (Hanus y otros, 2021, p. 5).

1.15.3. Necesidad de calibración local y adaptación de modelos

"Los modelos empíricos desarrollados con datos de una región específica a menudo fallan al ser aplicados en otras áreas" (Omer y otros, 2015, p. 149). Por ello, es necesario realizar "calibraciones locales con datos de campo para adaptar los modelos a las nuevas condiciones" (Gomez y otros, 2008, p. 1142).

Incluso con técnicas de transferibilidad, la "variación en propiedades del dosel y suelo conduce a la necesidad de realizar ajustes locales del modelo para un rendimiento óptimo" (Atzberger y otros, 2010, p. 127).

1.15.4. Requerimiento nutricional de la *Brachiaria brizantha* cv.

Además de los requerimientos nutricionales mencionados anteriormente, la *Urochloa brizantha* (pasto *brachiaria*) también necesita otros elementos para su adecuado crecimiento y desarrollo.

La aplicación de micronutrientes como zinc (Zn), boro (B), cobre (Cu) y molibdeno (Mo) puede ser necesaria en suelos deficientes en estos elementos (Villalobos & Arce, 2014). Se recomienda una fertilización con zinc de 2-5 kg/ha/año y con boro de 0.5-1 kg/ha/año (Argel & Humphreys, 1983)(Argel y Humphreys, 1983, como se citó en Villalobos & Arce, 2014).

Además, la *Urochloa brizantha* responde favorablemente a la aplicación de enmiendas calcáreas en suelos ácidos, ya que tiene una tolerancia limitada a la acidez (Villalobos & Arce, 2014). Se recomienda encalar para mantener el pH del suelo entre 5.5 y 6.5 (Argel & Humphreys, 1983, como se citó en Villalobos & Arce, 2014).

Por otro lado, es importante considerar que los requerimientos nutricionales pueden variar dependiendo de factores como el clima, el suelo, la edad de la pastura y la intensidad de pastoreo (Villalobos & Arce, 2014).

Tabla 1. Requerimiento nutricional de la *Brachiaria brizantha* cv.

Nutrientes	Requerimiento
N	100-300 kg/ha/año
P	20-50 kg/ha/año
K	80-200 kg/ha/año
Ca	20-40 kg/ha/año
Mg	10-20 kg/ha/año
S	10-20 kg/ha/año
Zn	2-5 kg/ha/año

(Villalobos & Arce, 2014).

CAPITULO II

2. INVESTIGACIONES EXPERIMENTALES AFINES AL PROYECTO DE INVESTIGACIÓN

A nivel internacional, diversos estudios han abordado la detección de deficiencias nutricionales en cultivos utilizando técnicas de teledetección. Mahajan y otros. (2014) utilizaron imágenes hiperespectrales para detectar deficiencias de nitrógeno, fósforo y potasio en trigo, logrando una precisión del 90% mediante análisis discriminante lineal. En maíz, Osborne y otros. (2002) demostraron que los índices espectrales derivados de imágenes satelitales Landsat predijeron exitosamente la concentración de nitrógeno foliar ($R^2=0.76$).

En el ámbito de los pastos, Mutanga y otros. (2004) utilizaron espectroscopía de campo para estimar la concentración de nitrógeno en pastizales de Sudáfrica, obteniendo modelos de regresión con R^2 de hasta 0.85. Por su parte, Pullanagari y otros. (2012) emplearon imágenes hiperespectrales aerotransportadas para mapear la calidad nutricional de pasturas en Nueva Zelanda, logrando estimaciones precisas de proteína cruda ($R^2=0.89$) y digestibilidad ($R^2=0.83$) mediante regresión por mínimos cuadrados parciales.

Enfocándose en deficiencias específicas, Pimstein y otros. (2011) detectaron deficiencias de fósforo en trigo usando índices espectrales derivados de imágenes multiespectrales, con una precisión del 87%. En cuanto a micronutrientes, Gaonkar & Nair. (2017) identificaron deficiencias de hierro en cultivos de fresa utilizando imágenes RGB de drones, alcanzando una precisión del 85% mediante algoritmos de aprendizaje automático.

A escala regional, Dash y otros. (2007) aplicaron imágenes MERIS para monitorear la dinámica estacional del contenido de clorofila en pastizales europeos, encontrando una fuerte correlación ($R^2=0.81$) con datos in situ. En Argentina, Druille y otros. (2015) utilizaron el índice de vegetación de diferencia normalizada (NDVI) derivado de MODIS para evaluar la productividad de pastizales templados, explicando el 61% de la variabilidad en la biomasa.

En el contexto de Ecuador, Asanza y otros. (2018) emplearon imágenes Landsat para mapear la cobertura y calidad de páramos andinos, logrando una precisión general del 84%. Aunque no se enfocaron directamente en deficiencias nutricionales, sus hallazgos sientan bases metodológicas para futuras investigaciones. En un estudio más específico, Paredes y otros.

(2020) utilizaron imágenes multispectrales de drones para detectar deficiencias de nitrógeno en cultivos de papa en la provincia de Carchi, alcanzando una precisión del 88% a través de modelos de regresión logística.

Respecto al pasto *Brachiaria*, Ramírez y otros. (2019) evaluaron el efecto de dosis de cal en un oxisol de la Amazonía ecuatoriana, encontrando que dosis de 1.5 y 3 ton/ha incrementaron significativamente el rendimiento y calidad nutricional. Aunque no emplearon teledetección, sus resultados sugieren que la deficiencia de calcio puede ser un factor limitante para este pasto en suelos ácidos.

En síntesis, la literatura internacional demuestra el potencial de la teledetección para detectar deficiencias nutricionales en diversos cultivos y pasturas. En Ecuador, algunos estudios han sentado bases metodológicas, pero la investigación específica en pastos *Brachiaria* es escasa. Por tanto, existe una clara oportunidad para aplicar técnicas de teledetección con drones para abordar esta problemática en el contexto local.

CAPÍTULO III

3. MATERIALES Y MÉTODOS

3.1. Localización de la unidad experimental

Hacienda de producción de ganado bovino lechero en el cantón Santo Domingo de los Colorados en la provincia de Santo Domingo de los Tsáchilas.

3.2. Caracterizaciones climáticas de la zona

Tabla 2. Características agroecológicas de la localidad

Características	Santo Domingo
Clima	Tropical húmedo
Temperatura (°C)	22 - 28
Humedad Relativa (%)	80 - 90
Heliofanía (Horas luz año ⁻¹)	1500 - 2000
Precipitación media anual (mm)	1200 - 1800
Altitud (msnm)	300 - 600

Fuente: Ministerio del Ambiente y Agua. (2021). Estudio de Zonificación Agroecológica de la Provincia de Santo Domingo de los Tsáchilas. Quito, Ecuador.

3.3. Variables

3.4. Variables independientes

Deficiencias nutricionales en el pasto

3.4.1. Métodos

- Análisis de suelo
- Análisis foliar
- Observación visual de síntomas
- Técnicas espectroscópicas

3.4.2. Frecuencia

Antes y después de eventos significativos

3.5. Variables dependientes.

Fotografías espectrales con dron

3.6. Instrumentos de medición

3.6.1. Materiales y equipos de campo

- ❖ Barreno para muestreo de suelo
- ❖ Medidor de clorofila (SPAD)

3.6.2. Materiales de oficina y muestreo

- ❖ Bolsas de papel para muestras
- ❖ GPS para georreferenciación
- ❖ Etiquetas y marcadores permanentes

3.6.3. Manejo del ensayo

Preparación del terreno

Se preparó el terreno donde ya estaba establecido el cultivo de pasto brachiaria en hacienda de producción de ganado bovino lechero en el cantón Santo Domingo de los Colorados en la provincia de Santo Domingo de los Tsáchilas.

Toma de muestras de suelo iniciales

Antes de realizar el vuelo para su respectiva toma de imagen, Se recolectaron muestras de suelo de diversas ubicaciones dentro del área de cultivo y se enviaron al laboratorio Agrolab para realizar un análisis preliminar del suelo.

Equipos empleados

Se empleó un dron Autel Evo 2 Pro 6K, el cual está equipado con una cámara de 6K para capturas de alta resolución, ofreciendo 20 megapíxeles para fotografías. Este dron también cuenta con una batería que proporciona hasta 40 minutos de tiempo de vuelo, sensores omnidireccionales para evitar obstáculos y un rango de transmisión de hasta 9 km, permitiendo una operación precisa y segura en el área de cultivo.

Procesamiento y análisis de datos

Para proceder a la toma de imágenes se estableció el área de vuelo y una altura de 150 metros. Una vez que se recibieron los resultados del laboratorio, se analizaron los datos para determinar si es efectivo esta herramienta para el uso de los análisis que se puede realizar y evitar el tiempo de demora de los análisis tradicionales.

CAPÍTULO IV

4. RESULTADOS Y DISCUSIÓN

Los resultados obtenidos fueron los siguientes:

4.1. Análisis de suelo

La Tabla 1 presenta los resultados de un análisis de suelo realizado en un terreno cultivado con pasto *Brachiaria sp.* Los nutrientes analizados incluyen Nitrógeno (N), Fósforo (P), Potasio (K), Calcio (Ca), Magnesio (Mg), Azufre (S), Cobre (Cu), Boro (B), Hierro (Fe), Zinc (Zn) y Manganeso (Mn). Las mediciones se dan en partes por millón (ppm) o miliequivalentes por 100 gramos (meq/100 g).

Tabla 3. Resultados del análisis de suelo realizado en el terreno cultivado.

Nutriente	Edáfico
N	20,96 ppm
P	3,42 ppm
K	0,36 meq/100 g
Ca	8,00 meq/100 g
Mg	1,02 meq/100 g
S	4,21 ppm
Cu	5,4 ppm
B	0,49 ppm
Fe	119,5 ppm
Zn	13,8 ppm
Mn	6,9 ppm

La concentración de nitrógeno (N) es de 20,96 ppm. Este nivel es adecuado para el crecimiento de *Brachiaria sp.* El nitrógeno es esencial para la síntesis de proteínas y el crecimiento vegetativo. El contenido de fósforo (P) es de 3,42 ppm. Este nivel es relativamente

bajo y podría limitar el desarrollo radicular y la producción de biomasa. El fósforo es crucial para la fotosíntesis y el metabolismo energético.

La concentración de potasio (K) es de 0,36 meq/100 g. El potasio es vital para la regulación osmótica y la resistencia a enfermedades. Sin embargo, este valor podría ser subóptimo, afectando negativamente la calidad del pasto. El nivel de calcio (Ca) es de 8,00 meq/100 g. Este nivel es suficiente para asegurar la integridad estructural de las células y el crecimiento adecuado del pasto. El magnesio (Mg), con una concentración de 1,02 meq/100 g, es adecuado para la fotosíntesis, ya que forma parte central de la molécula de clorofila.


La cantidad de azufre (S) es de 4,21 ppm. Este nivel es generalmente suficiente para la síntesis de aminoácidos y proteínas esenciales. La concentración de cobre (Cu) es de 5,4 ppm, lo cual es adecuado para el funcionamiento enzimático y la fotosíntesis. Con un nivel de 0,49 ppm, el boro (B) es suficiente para el crecimiento de las plantas. El boro es importante para la formación de paredes celulares y la reproducción. La concentración de hierro (Fe) es de 119,5 ppm. Este valor es alto y garantiza la disponibilidad de hierro para la síntesis de clorofila y la fotosíntesis.

Finalmente, la concentración de zinc (Zn) es de 13,8 ppm, adecuada para la síntesis de auxinas y la activación de numerosas enzimas. Con un nivel de 6,9 ppm, el manganeso (Mn) es suficiente para la fotosíntesis y la defensa contra enfermedades. Estos resultados proporcionan una visión detallada de la salud del suelo en el terreno cultivado con pasto *Brachiaria* sp.

En comparación con otros estudios, los resultados de este análisis de suelo muestran algunas similitudes y diferencias. Por ejemplo, un estudio realizado en Brasil investigó el impacto de diferentes variedades de *Brachiaria* en las propiedades del suelo y encontró que todas las variedades mejoraron la porosidad del suelo, el contenido de P, el carbono orgánico y las funciones potenciales (Merloti y otros, 2023). Otro estudio evaluó los efectos de las concentraciones de ácido húmico en el crecimiento de *Brachiaria brizantha* y las propiedades de la solución del suelo de suelos tropicales contrastantes, en este estudio, la adición de 30-40 mg kg⁻¹ de carbono-ácido húmico aumentó la proliferación de raíces en un 76-89% en los suelos menos amortiguados (Valenciano y otros., 2024).

4.2. Imágenes RGB

Figura 1. Imagen RGB del área del contenido



Si bien esta imagen puede indicar áreas de estrés en la vegetación, es importante tener en cuenta que una imagen RGB por sí sola no puede diagnosticar deficiencias nutricionales específicas. Se necesitarían pruebas de suelo y/o plantas para determinar las deficiencias exactas.

Sin embargo, basándonos en los patrones generales de la imagen, podemos inferir lo siguiente:

Áreas rojas/naranjas extensas: Podrían sugerir deficiencias generalizadas de macronutrientes como nitrógeno (N), fósforo (P) o potasio (K).

Patrones irregulares o manchas: Podrían indicar deficiencias de micronutrientes como hierro (Fe), manganeso (Mn) o zinc (Zn).



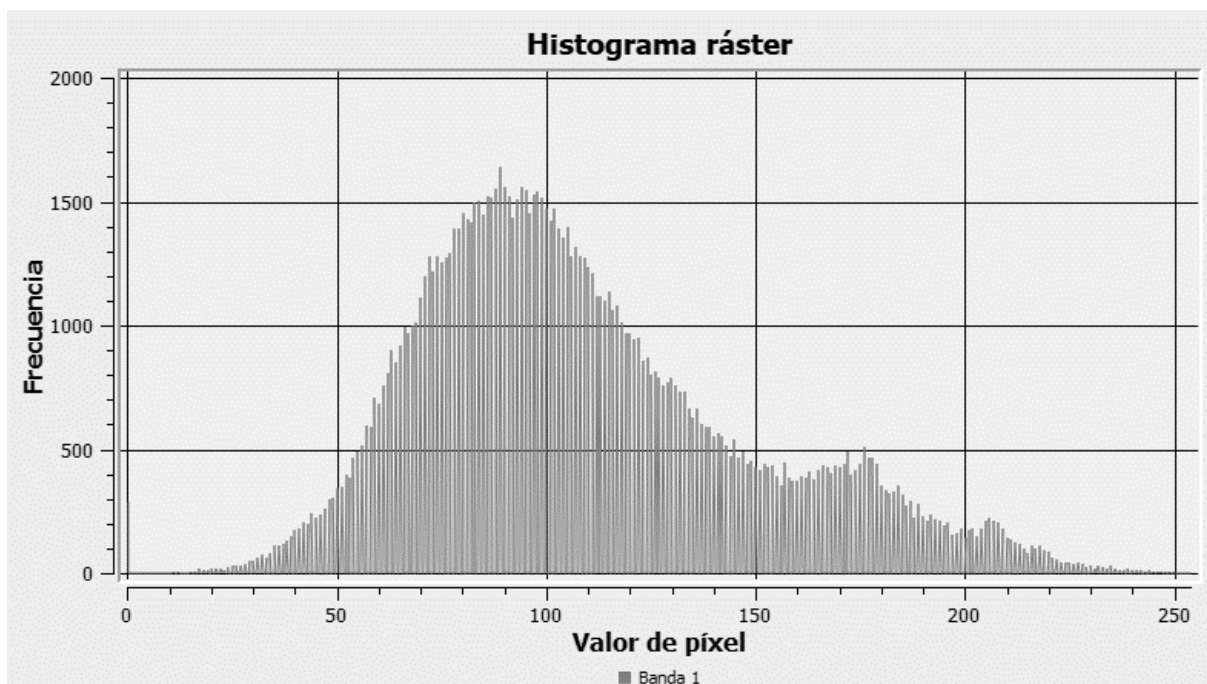


Figura 2. *Histograma Ráster Banda Roja*



La imagen que se proporciona muestra un histograma ráster, que es una representación gráfica de la distribución de los valores de píxel en una imagen (o en este caso, probablemente una sola banda de una imagen multispectral o hiperespectral).

Eje X (Valor de píxel): Representa el rango de valores de brillo o intensidad que los píxeles pueden tener en la "Banda 1". En este caso, el rango va de 0 a 250.

Eje Y (Frecuencia): Muestra cuántos píxeles en la imagen tienen un valor de brillo específico. Cuanto más alta sea la barra en un valor de píxel dado, más píxeles en la imagen tienen ese brillo.


Forma del Histograma

La forma general del histograma se asemeja a una campana o curva normal, lo que indica que la mayoría de los píxeles tienen valores de brillo en el rango medio.

Hay un pico pronunciado alrededor del valor de píxel 100, lo que significa que este es el valor de brillo más común en la imagen.

La distribución es asimétrica, con una cola más larga hacia la derecha, lo que sugiere que hay algunos píxeles con valores de brillo mucho más altos (más brillantes) que la mayoría.

Figura 3. *Histograma Ráster Banda Verde*



Banda Verde: Esta banda es particularmente sensible a la concentración de clorofila en las hojas, lo que la hace muy útil para evaluar el estado de salud y nutrición de las plantas.

Rango de valores: Los valores de píxel van de 0 a 250, lo que es típico para imágenes de 8 bits. En la banda verde, valores más altos generalmente indican mayor reflectancia del verde.

Distribución: La forma del histograma sugiere una variabilidad significativa en la reflectancia verde del pasto *Brachiaria sp.*, en su estudio.

Pico principal: El pico alrededor del valor 100 probablemente representa el estado más común de las plantas en su muestra. Esto podría indicar un nivel "promedio" de salud o contenido de clorofila.

Interpretación nutricional:

Valores bajos (lado izquierdo): Podrían indicar plantas con deficiencias nutricionales severas, especialmente en nitrógeno, que afecta directamente la producción de clorofila.

Valores medios: Representan plantas con niveles moderados de clorofila, posiblemente con deficiencias nutricionales leves o en estado de salud intermedio.

Valores altos (lado derecho): Podrían corresponder a plantas más saludables o con mejor estado nutricional.

Asimetría: La ligera asimetría hacia la derecha podría sugerir que hay algunas áreas del pasto con mayor contenido de clorofila o mejor estado nutricional.

Potencial para análisis:

Se podrían establecer umbrales para categorizar diferentes niveles de salud o deficiencia nutricional basados en la reflectancia verde.

La combinación de esta banda con otras (como el infrarrojo cercano) podría permitir el cálculo de índices de vegetación más precisos para la detección de deficiencias.

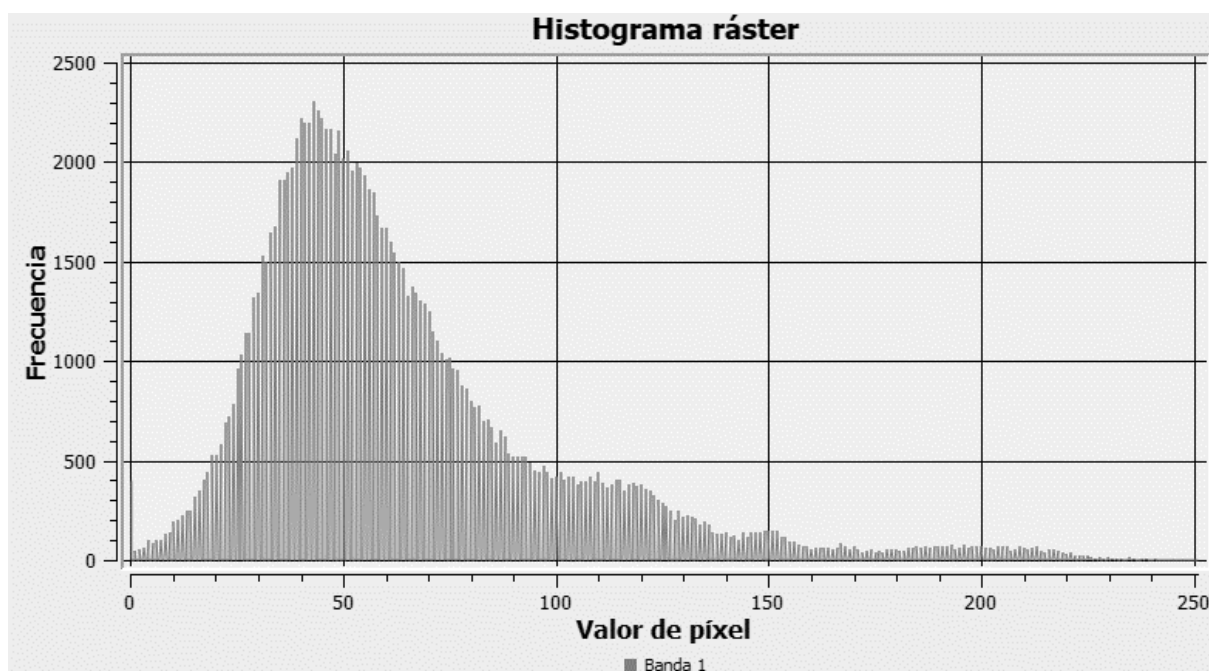
Consideraciones:

La reflectancia en la banda verde puede verse afectada por factores como la estructura de la hoja, el contenido de agua y la densidad del dosel, no solo por el contenido de clorofila.

Para un análisis más completo, sería beneficioso comparar este histograma con los de otras bandas espectrales.

Este histograma proporciona una base sólida para identificar y posiblemente cuantificar diferentes estados nutricionales en su muestra de *Brachiaria sp.*

Figura 4. *Histograma Ráster Banda Azul*



Distribución general:

El histograma muestra una distribución asimétrica con un pico principal alrededor del valor de píxel 50.

Hay una cola larga hacia la derecha, extendiéndose hasta valores cercanos a 250.

Pico principal:

El pico alrededor del valor 50 sugiere que la mayoría de las plantas en su muestra tienen una reflectancia azul relativamente baja.

Esto es típico en vegetación sana, ya que la clorofila absorbe fuertemente la luz azul.

Cola larga:

La cola extendida hacia valores más altos podría indicar áreas con menor absorción de luz azul.

Esto podría corresponder a plantas con menor contenido de clorofila, posiblemente debido

a deficiencias nutricionales o estrés.

Interpretación en contexto de nutrición:

Valores bajos (cerca del pico): Probablemente representan plantas más saludables con buen contenido de clorofila.

Valores medios: Podrían indicar plantas con deficiencias nutricionales moderadas o estrés leve.

Valores altos (en la cola): Posiblemente indican plantas con deficiencias nutricionales severas, especialmente en nitrógeno, o plantas muy estresadas.

Comparación con la banda verde:

La distribución es diferente a la de la banda verde, lo cual es esperado y útil para el análisis multibanda.

La banda azul parece ser más sensible a variaciones en el estado de la planta, mostrando una distribución más amplia.

Potencial para análisis:

La amplia distribución ofrece buena oportunidad para diferenciar varios estados de salud de la planta.

Combinando esta información con la banda verde, se podría crear un índice más robusto para detectar deficiencias nutricionales.

Consideraciones:

La reflectancia en la banda azul puede ser afectada por factores como el contenido de agua en la hoja y la estructura del dosel.

Es importante considerar las condiciones atmosféricas al interpretar la reflectancia en la banda azul, ya que es más susceptible a la dispersión atmosférica.

Implicaciones para su investigación:

Este histograma sugiere que hay una variabilidad significativa en el estado nutricional o de estrés de las plantas de *Brachiaria sp.* en su estudio.

Podría ser útil para identificar diferentes niveles de deficiencia nutricional, especialmente cuando se combina con información de otras bandas.

4.3. Análisis foliar

El análisis foliar del pasto *Brachiaria sp.* muestra un contenido de nitrógeno del 1%, lo cual es adecuado para el crecimiento vigoroso del pasto, dado que el nitrógeno es esencial para la formación de proteínas y el crecimiento foliar. Este nivel indica que las plantas están recibiendo suficiente nitrógeno del suelo o de fuentes de fertilización.

Tabla 4. Resultados del análisis de suelo realizado en el terreno cultivado.

Nutriente	Análisis foliar
N	1 %
P	0,12 %
K	1,51 %
Ca	0,71 %
Mg	0,06 %
S	0,14 %
Cu	7 ppm
B	28,81 ppm
Fe	388 ppm
Zn	155 ppm
Mn	29 ppm

El fósforo, con una concentración de 0,12%, está dentro del rango adecuado para *Brachiaria sp.* Este nutriente es crucial para la transferencia de energía y el desarrollo de raíces. La cantidad de fósforo en las hojas sugiere que las plantas tienen un suministro suficiente para mantener sus

funciones metabólicas esenciales. La concentración de potasio es de 1,51%, lo cual es bastante favorable para el pasto. El potasio juega un papel clave en la regulación osmótica y en la activación de enzimas, además de ayudar a las plantas a resistir enfermedades y estrés abiótico. Este nivel de potasio indica que las plantas están bien equipadas para enfrentar condiciones adversas.

El contenido de calcio es de 0,71%, un valor adecuado para mantener la integridad estructural de las células y la comunicación celular. El calcio es esencial para la estabilidad de las paredes celulares y para el desarrollo general de la planta, lo que sugiere que las plantas tienen acceso a suficiente calcio del suelo. La cantidad de magnesio es de 0,06%, lo cual es relativamente bajo, pero aún dentro del rango necesario para la fotosíntesis, dado que el magnesio es un componente central de la molécula de clorofila. Las plantas de *Brachiaria* sp. con este nivel de magnesio pueden realizar la fotosíntesis de manera efectiva, aunque un aumento en la disponibilidad de magnesio podría mejorar aún más el crecimiento.

El azufre está presente en una concentración de 0,14%, lo que es suficiente para la síntesis de aminoácidos y proteínas. Este nivel sugiere que las plantas pueden realizar la síntesis de compuestos esenciales sin restricciones por falta de azufre, lo cual es crucial para su crecimiento y desarrollo. La concentración de cobre es de 7 ppm, lo que es adecuado para el funcionamiento enzimático y la fotosíntesis. El cobre es un micronutriente esencial para las plantas, y su nivel adecuado sugiere que no hay deficiencia de este nutriente en el cultivo.

El boro está presente en 28,81 ppm, un nivel que es suficiente para la formación de paredes celulares y la fertilidad de las plantas. La concentración de boro en las hojas indica que las plantas tienen un buen suministro de este micronutriente, crucial para su desarrollo reproductivo. El hierro, con una concentración de 388 ppm, es bastante alto y garantiza la disponibilidad para la síntesis de clorofila y otros procesos metabólicos esenciales. Este alto nivel de hierro sugiere que las plantas tienen una excelente capacidad para la fotosíntesis y un buen estado de salud general.

El zinc está presente en 155 ppm, un valor que es muy favorable para la activación de numerosas enzimas y la síntesis de auxinas. Este alto nivel de zinc indica que las plantas pueden

crecer vigorosamente y resistir enfermedades. Finalmente, el manganeso, con una concentración de 29 ppm, es adecuado para la fotosíntesis y la defensa contra enfermedades. El manganeso es esencial para la actividad enzimática en las plantas, y este nivel sugiere que las plantas de *Brachiaria* sp. están bien equipadas para realizar sus funciones metabólicas de manera eficiente.

El estudio de Bueno, (2013), sobre el contenido de nutrientes en el forraje del pasto *Brachiaria* revela que la fertilización adecuada con nitrógeno y azufre es crucial para mejorar la productividad de los sistemas pastorales. Se observó que la aplicación de nitrógeno incrementa significativamente los niveles de este nutriente en las hojas verdes y en las estructuras de la planta, mientras que el azufre también juega un papel importante en la producción de perfilhos y en el peso seco total del forraje. La combinación de ambos nutrientes no solo favorece el crecimiento de la planta, sino que también reduce la proporción de hojas secas, lo que sugiere que una fertilización balanceada puede optimizar la calidad del forraje y, por ende, la eficiencia en la producción animal.

CAPITULO V

5. CONCLUSIONES

Se alcanzaron resultados significativos que confirman la utilidad de la tecnología de imágenes espectrales capturadas por drones para la gestión nutricional de los potreros. La capacidad de las fotografías espectrales para identificar deficiencias nutricionales en los pastos fue evaluada exitosamente, demostrando que pueden detectar de manera precisa las carencias antes y después de realizar enmiendas.

Además, se identificaron síntomas visuales tradicionales de deficiencias nutricionales, como cambios en la coloración y crecimiento del pasto, los cuales fueron correlacionados con las imágenes espectrales capturadas por drones, estableciendo correlaciones significativas que validan el uso de esta tecnología como herramienta complementaria para una evaluación más rápida y precisa que los métodos tradicionales. Basados en los resultados obtenidos, se propusieron recomendaciones prácticas para el manejo nutricional de los potreros, incluyendo la implementación regular de monitoreos espectrales para la detección temprana de deficiencias y la capacitación de los gestores en el uso de esta tecnología.

CAPITULO VI

6. RECOMENDACIONES

Fertilización con fósforo: El nivel de fósforo en el suelo (3,42 ppm) es relativamente bajo. Se recomienda aplicar fertilizantes fosfatados para mejorar el desarrollo radicular y la producción de biomasa. Una opción podría ser el superfosfato triple o el fosfato diamónico.

Ajuste de potasio: El nivel de potasio en el suelo (0.36 meq/100 g) es subóptimo. Se sugiere aumentar la aplicación de fertilizantes potásicos, como el cloruro de potasio o el sulfato de potasio, para mejorar la regulación osmótica y la resistencia a enfermedades del pasto.

Suplementación con magnesio: Aunque el nivel de magnesio en el suelo es adecuado, el análisis foliar muestra un nivel relativamente bajo (0,06%). Se recomienda una ligera suplementación con magnesio, posiblemente mediante la aplicación de sulfato de magnesio o dolomita.

Monitoreo de micronutrientes: A pesar de que los niveles de micronutrientes parecen adecuados, es importante mantener un monitoreo continuo, especialmente del zinc y el manganeso, dado que la imagen RGB sugiere posibles deficiencias localizadas.

Manejo del pH: Aunque no se proporcionó información sobre el pH del suelo, es crucial mantenerlo en un rango óptimo para la absorción de nutrientes. Se recomienda realizar un análisis de pH y, si es necesario, aplicar cal para ajustarlo.

Manejo del riego: La imagen RGB muestra áreas de estrés que podrían estar relacionadas con el manejo del agua. Se sugiere revisar y optimizar el sistema de riego para asegurar una distribución uniforme del agua.

REFERENCIAS BIBLIOGRÁFICAS

- Abdel-Rahman, E. M., Mutanga, O., Odindi, J., Adam, E., Odindo, A., y Ismail, R. (2017). Discriminación de deficiencias de nitrógeno y agua en naranjas utilizando espectros de reflectancia de hojas y datos hiperespectrales. *Revista Internacional de Sensores Remotos*, 5(38), 1349-1372.
<https://doi.org/https://doi.org/10.1080/01431161.2016.1264032>
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., y Sousa, J. J. (2017). Monitoreo hiperspectral de cultivos con vehículos aéreos no tripulados: una revisión. *Remote Sensing*, 11(9), 1144. <https://doi.org/https://doi.org/10.3390/rs9111144>
- Adler-Golden, S. M., Levine, R. Y., Richtsmeier, S. C., Bernstein, L. C., Felde, G., Anderson, G. P., . . . Burke, H.-H. (1999). Atmospheric correction of shortwave spectral imagery. *AVIRIS 1999 Proceedings*.
- Anschütz, U., Becker, D., y Shabala, S. (2014). Going beyond nutrition: Integration of emerging nutritional and regulatory roles of plants' potassium. *Current Opinion in Plant Biology*, 22, 92-102.
- Argel, P. J., y Humphreys, L. R. (1983). *Manejo de pasturas tropicales para la producción de leche*. Instituto Colombiano Agropecuario.
- Asanza, M., Rodríguez, D., Benítez, A., y Gutierrez, J. (2018). Mapeo de la cobertura y uso del suelo en los páramos andinos utilizando imágenes Landsat: Un estudio de caso en el páramo del Ángel, Ecuador. *Revista de Teledetección*, 51, 139-153.
- Atzberger, C., Darvishzadeh, R., Schlerf, M., y Le Maire, G. (2010). Suitability and adaptation of PROSAIL radiative transfer model for hyperspectral grassland studies. *Remote Sensing Letters*, 4(1), 55-64.
- Barber, S. A. (1995). *Soil nutrient bioavailability: A mechanistic approach*. John Wiley & Sons.
- Barreto, L., Goncalves, R. S., Vieira, R., Batista, R., Ceddia, M. B., y Justiniano, W. (2020). Aplicación de la fotogrametría con drones de bajo costo para la caracterización de la

- superficie del suelo. *Revista Brasileira de Ciencia do Solo*(44).
<https://doi.org/https://doi.org/10.36783/18069657rbcs20190106>
- Behmann, J., Steinrücken, J., y Plümer, L. (2014). Detection of early plant stress responses in hyperspectral images. *SPRS Journal of Photogrammetry and Remote Sensing*, 93, 98-111. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2014.03.016>
- Blackburn, G. A. (2007). Hyperspectral remote sensing of plant pigments. *Journal of Experimental Botany*, 58(4), 855-867.
<https://doi.org/https://doi.org/10.1093/jxb/erl123>
- Blackmer, T. M., Schepers, J. S., y Ferrie, G. J. (1994). Detección remota de deficiencias de nitrógeno en el cultivo de maíz. En J. W. Frye, G. S. Wilkinson, y B. J. Blair, *Monografías SSSA* (pp. 147-162). Soil Science Society of America.
- Burai, P., Deák, B., Valkó, O., y Tomor, T. (2015). Clasificación de la cobertura vegetal seminatural utilizando datos hiperespectrales de drones. *Remote Sensing*, 5(7), 5816-5842.
- Carrivick, J. L., Smith, M. W., y Quincey, D. J. (2016). Estructura a partir del movimiento en la geomorfología del Ártico. Potsdam, Alemania: Springer International Publishing.
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., y Grégoire, J.-M. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, 77(1), 22-33. [https://doi.org/https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/https://doi.org/10.1016/S0034-4257(01)00191-2)
- Chonay, P. (1981). *Efecto de la fertilización foliar sobre la compensación de la fijación biológica de nitrógeno por Rhizobium phaseoli en frijol (Phaseolus vulgaris L.)*. Tesis de M. en C. CEDAF-CP.
- Congalton, R. G., y Green, K. (2009). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. 2nd ed. (segunda edición)*. CRC Press.
- Cruz, J. C. (2011). *Eficiencia Agronomica y Econimica del manejo de la fertilizacion en*

banano en un suelo de la depresion del Lago de Valencia. Venezuela:
[http://www.sian.inia.gob.ve/repositorio/congresos/CVCS19/uso_
manejo_suelo/UMS15.pdf.](http://www.sian.inia.gob.ve/repositorio/congresos/CVCS19/uso_manejo_suelo/UMS15.pdf)

Dash, J., Mathur, A., Foody, G. M., Curran, P. J., Chipman, J. W., y Lillesand, T. M. (2007). Land cover classification using multi-temporal MERIS vegetation indices. *International Journal of Remote Sensing*, 28(6), 1137-1159.
<https://doi.org/https://doi.org/10.1080/01431160600784259>

Defoor, K. R., Hargrove, W. W., y Hanlon, E. A. (2017). Evaluación de los síntomas visuales de la deficiencia nutricional del pasto bahía (*Paspalum notatum* Flugge). *Communications in Soil Science and Plant Analysis*, 17(48), 2083-2094.

Demera, C. F. (2018). *NIVELES DE FERTILIZACIÓN EN LAS PROPIEDADES QUÍMICAS DEL SUELO Y LA EFICIENCIA EN EL USO DE NUTRIENTES CV DOMINICO HARTÓN*. Ecuador:
[https://repositorio.uleam.edu.ec/bitstream/123456789/120/1/ULEAM-AGRO-0011.pdf.](https://repositorio.uleam.edu.ec/bitstream/123456789/120/1/ULEAM-AGRO-0011.pdf)

Dobermann. (2005). *Nitrogen Use Efficiency – State of the Art. University of Nebraska - Lincoln, Agronomy & Horticulture* -. Faculty Publications. Nebraska: Agronomy & Horticulture -- Faculty Publications.

Dobermann., A. (2005). *Nitrogen Use Efficiency – State of the Art. University of Nebraska - Lincoln, Agronomy & Horticulture*. Faculty Publications. Nebraska: Agronomy & Horticulture.

Dor, E. B., Cappelon, G., Atzberger, C., y Schneebeli, S. (2003). Mapping vegetation characteristics for monitoring semi-arid areas using airborne hyperspectral remote sensing and ancillary information. *International Journal of Remote Sensing*, 14(12), 2527-2552.

Druille, M., Golluscio, R. A., Garbulsky, M. F., Remy, V. D., y Oyarzabal, M. (2015). Controles ambientales y estructurales de la productividad primaria neta aérea de

- pastizales templados semiáridos: Un estudio a largo plazo. *Journal of Vegetation Science*, 26(2), 267-276.
- Ediriwickrema, J., y Khorram, S. (1997). Hierarchical cluster-based facility location analysis. *Photogrammetric Engineering & Remote Sensing*, 63(9), 1015-1024.
- Ediriwickrema, J., y Khorram, S. (1997). Hierarchical cluster-based facility location analysis. *Photogrammetric Engineering & Remote Sensing*, 63(9), 1015-1024.
- ESPAC. (2019). *Encuesta de Superficie y Producción Agropecuaria Continua*. Ecuador: https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_agropecuarias/espac/espac-2019/Presentacion%20de%20los%20principales%20resultados%20ESPAC%202019.pdf.
- Espinisa, J. A. (2018). *NUTRICIÓN VEGETALEXPORTACIÓN Y EFICIENCIA DEL USO DE NUTRIENTES EN PLÁTANO*. Ecuador: <https://www.3ciencias.com/wp-content/uploads/2020/03/Nutrici%C3%B3n-vegetal-exportaci%C3%B3n-y-eficiencia-del-uso-de-nutrientes-en-pl%C3%A1tano.pdf>.
- FAO. (2002). *Los fertilizantes y su uso*. www.fao.org > ...
- FAO. (2011). *Los Fertilizantes y su Uso*. Roma, Italia: R. Marbeuf.
- FAO. (2014). *Organizacion de las Naciones Unidas para la Alimentacion y Agricultura*. <http://www.fao.org/faostat/es#data/QC>.
- Fernandez, V. (2015). *Fertilización Foliar*. https://researchgate.net/publication/208908842_Fertilizacion-Foliar
- Foody, G. M. (2009). Sample Scheme Considerations for Accurate Ground Data for Image Classification Accuracy Assessment (GAIA). *International Journal of Remote Sensing*, 30(21), 5693-5709.
- Furcal, P. B. (2013). *Respuesta del plátano a la fertilización con P, K y S durante el primer*

ciclo productivo. http://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S1659-1321013000200008.

Gamon, J. A., Peñuelas, J. J., y Field, C. B. (1992). A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, 1(41), 35-44. [https://doi.org/https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/https://doi.org/10.1016/0034-4257(92)90059-S)

Gaonkar, O. D., y Nair, S. K. (2017). Identification of iron deficiency in strawberry leaves using image processing techniques. En *2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)* (pp. 886-891). IEEE.

Gitelson, A. A., Gritz, Y., y Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 3(160), 271-282. <https://doi.org/https://doi.org/10.1078/0176-1617-00887>

Gitelson, A. A., Kaufman, Y. J., y Merzlyak, M. N. (1996). Remote sensing of plant pigment concentrations in vegetation. Principles, techniques, and applications. *Remote Sensing Reviews*, 1-3(14), 179-205.

Gomez, C., Viscarra Rossel, R. A., y McBratney, A. B. (2008). Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma*, 146(3-4), 403-411.

Govindaraju, R. (1994). Carotenoid index inferred from plant leaf reflectance versus leaf nitrogen content. *International Journal of Remote Sensing*, 15(8), 1771-1784.

Guzman, M. (2012). *CARACTERÍSTICAS DE LOS FERTILIZANTES PARA SU USO EN LA FERTIRRIGACIÓN*.

https://www.researchgate.net/publication/257416472_CHARACTERISTICAS_DE_LOS_FERTILIZANTES_PARA_SU_USO_EN_LA_FERTIRRIGACION.pdf

Haifa. (2014). *Recomendaciones nutricionales para Banano*. Colombia: <https://www.haifa->

group.com/sites/default/files/crop/Banana_Spanish.pdf.

- Hansch, R., y Mendel, R. R. (2009). Physiological functions of mineral micronutrients (Cu, Zn, Mn, Fe, Ni, Mo, B, Cl). *Current Opinion in Plant Biology*, 12(3), 259-266.
<https://doi.org/https://doi.org/10.1016/j.pbi.2009.05.006>
- Hanus, J., Dor, E. B., Atzberger, C., y Streza, M. (2021). Transferability of hyperspectral remote sensing models for estimating grassland biophysical variables. *Remote Sensing*, 13(18), 3601.
- Hassan-Esfahani, L., Torres-Rua, A., Jensen, A., y McKee, M. (2017). Evaluación de mediciones de temperatura de superficie terrestre obtenidas a partir de drones pequeños y térmicos y fotogrametría aérea. *Revista Internacional de Sensores Remotos*, 8, 10(38), 2639, 2661.
<https://doi.org/https://doi.org/10.1080/01431161.2017.1292832>
- Hassanin, R., El-Sheimy, N., Taha, M., y Abd-El-Samie, F. (2019). Fotogrametría con drones: conceptos, aplicaciones y precisión. *Revista Internacional de Ciencias de Sensores Remotos*, 19(40), 7694, 7726.
<https://doi.org/https://doi.org/10.1080/01431161.2019.1637276>
- Hawkesford, M., Horst, W., Kichey, T., Lambers, H., Schjoerring, J., Møller, I. S., y White, P. (2012). Functions of macronutrients. En P. Marschner, *Marschner's Mineral Nutrition of Higher Plants* (pp. 135-189). Academic Press.
- Hermans, C., Bourgis, F., Faucher, M., Strasser, R. J., Delrot, S., y Verbruggen, N. (2006). Leaf mitochondria modulate whole cell redox homeostasis, set antioxidant capacity, and determine stress resistance through altered signaling and diurnal regulation. *The Plant Cell*, 18(3), 720-739.
- Hernández, I., y Munné-Bosch, S. (2015). Linking phosphorus availability with photo-oxidative stress in plants. *Journal of Experimental Botany*, 66(10), 2889-2900.
<https://doi.org/https://doi.org/10.1093/jxb/erv056>

- Herrera, M. &. (2011). *MANEJO INTEGRADO DEL CULTIVO DE PLÁTANO*.
UNIVERSIDAD NACIONAL AGRARIA LA MOLINA :
http://www.agrobanco.com.pe/pdfs/capacitacionesproductores/Platano/MANEJO_INTEGRADO_DEL_CULTIVO_DE PLATANO. pdf
- Herrera., K. A. (2018). *NIVELES DE FERTILIZACIÓN EN LAS PROPIEDADES QUÍMICAS DEL SUELO Y LA EFICIENCIA EN EL USO DE NUTRIENTES CVCURARE ENANO*. Ecuador:
<https://repositorio.ulead.edu.ec/bitstream/123456789/94/1/ULEAM-AGRO-0010.pdf>.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölonen, I., Hakala, T., Litkey, P., . . . Pesonen, L. (2013). Procesamiento y evaluación de características de imágenes hiperespectrales y conjuntos de datos obtenidos con un sistema de imágenes aéreas de la próxima generación. *Revista de Sensores Remotos*, 11(5), 6047, 6083.
<https://doi.org/https://doi.org/10.3390/rs5116047>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 3(25), 295-309. [https://doi.org/https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/https://doi.org/10.1016/0034-4257(88)90106-X)
- INAMHI. (2017). *ANUARIO METEOROLÓGICO*. Ecuador:
http://www.serviciometeorologico.gob.ec/docum_institucion/anuarios/meteorologicos/Am_2013.pdf.
- INEC. (2011). *Instituto Nacional de Estadísticas y Censos. Datos Estadísticos*. Encuesta de superficie y producción agropecuaria: http://www.inec.gob.ec/espac_publicaciones/espac-2011/INFORME_EJECUTIVO%202011.pdf.
- Jacquemoud, S., y Ustin, S. L. (2001). Leaf optical properties: A state of the art. En *En Proceedings of the 8th International Symposium Physical Measurements & Signatures in Remote Sensing* (pp. 223-332). CNES.
- Kalaji, H. M., Schansker, G., Brestic, M., Bussotti, F., Calatayud, A., Ferroni, L., . . . Bąba, W. (2017). Frequently asked questions about chlorophyll fluorescence, the sequel.

Photosynthesis Research, 132(2), 221-248.

<https://doi.org/https://doi.org/10.1007/s11120-016-0318-y>

Kawamura, K., Watanabe, N., Sakanoue, S., Lee, H. L., Inoue, Y., y Odagawa, S. (2011).

Mapeo de deficiencias nutricionales en pasturas mediante imágenes hiperespectrales.

Revista Internacional de Sensores Remotos, 24(32), 8766-8781.

López, A. E. (1995). *Manual de nutrición y fertilización del banano*. nla.ipni.net › region ›

nla.nsf › N F Banano.002.002.pdf › N F Banano

Lopez, D. (2017). *EL CALCIO EN LA PRODUCCION Y CALIDAD DEL FRUTO EN EL*

CULTIVO DE PLATANO (Musa paradisiaca L.) CV BARRAGANETE. . Ecuador:

<https://repositorio.uleam.edu.ec/bitstream/123456789/122/1/ULEAM-AGRO-0013.pdf>.

Lopez., P. J. (2018). *NIVELES DE FERTILIZACIÓN EN LA MORFO-FISIOLOGIA,*

PRODUCCIÓN Y CALIDAD DEL PLÁTANO BARRAGANETE (Musa paradisiaca

AAB. Ecuador: <https://repositorio.uleam.edu.ec/bitstream/123456789/92/1/ULEAM-AGRO-0008.pdf>.

Louw-Gaume, A. E., Rao, I. M., Gaume, A. J., y Frossard, E. (2010). Potential constraints to

nutrient management in tropical pasture systems. En *Constraints to efficient nutrient use in tropical pastures* (pp. 12-29). ACIAR Proceedings.

Maes, W. H., y Steppe, k. (2019). Perspectivas de sensores remotos con drones para la gestión

de cultivos: una revisión. *Remote Sensing*, 23(11), 2821.

<https://doi.org/https://doi.org/10.3390/rs11232821>

MAGAP. (2015). *Boletín Situacional Plátano*. Ministerio de Agricultura y Ganadería,

Coordinación general del sistema de información nacional, Quito. Ecuador:

http://sinagap.agricultura.gob.ec/phocadownloadpap/cultivo/2016/boletin_situacional_platano_2015.pdf .

Mahajan, G. R., Sahoo, R. N., Pandey, R. N., Gupta, V. K., y Kumar, D. (2014). Using

- hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). *Precision Agriculture*, 15(2), 499-522.
<https://doi.org/https://doi.org/10.1007/s11119-014-9348-7>
- Mariotto, I., Gutschick, V. P., y Serbin, S. P. (2013). Spectroscopic estimations of leaf biochemical content in mixed grasslands. *Ecology & Management*, 5(66), 568, 577.
<https://doi.org/https://doi.org/10.2111/REM-D-12-00132.1>
- Marschner, P. (2012). *Marschner's mineral nutrition of higher plants (3rd ed.)*. Academic Press.
- Mendoza, L. (Mendoza, L.). *Densidades de siembra del plátano barraganete en las propiedades morfo-fisiológicas, producción y exportación de macronutrientes*.
- Mendoza., D. (2018). *EFEECTO DE LA FERTILIZACIÓN CON MAGNESIO EN EL CULTIVO DEL PLÁTANO (Musa paradisiaca L.) CV. BARRAGANETE*. El Carmen-Ecuador: <https://repositorio.ulead.edu.ec/bitstream/123456789/91/1/ULEAM-AGRO-0007.pdf>.
- Miles, J. W., Do Valle, C. B., Rao, I. M., y Euclides, V. P. (2004). *Brachiaria híbridos: un camino hacia el desarrollo de pasturas de alta productividad y persistencia*. *Actas del Taller "Hibridación de Brachiaria para la Producción de Forraje"*, Brasilia, Brasil.
- Mirik, M., Michels Jr, G. J., Kassymzhanova-Mirik, S., Elliott, N. C., Catana, V., Jones, D. B., y Bowling, R. (2006). Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. *Computers and Electronics in Agriculture*, 51(1-2), 86-98.
<https://doi.org/https://doi.org/10.1016/j.compag.2005.11.004>
- Miura, T., Yoshioka, H., Fujiwara, K., y Yamamoto, H. (2008). Inter-calibration of ASTER VNIR and SWIR radiometers using rays matched on the sunlit areas of the moon. *IEEE Transactions on Geoscience and Remote Sensing*, 46(4), 1030-1038.
- Molina, E. (2002). *Fertilización Foliar: Principios y Aplicación*.

www.cia.ucr.ac.cr>pdf>memorias>Memorias Curso fertilizacion foliar. pdf

- Morales, L. U. (2009). *Respuesta de genotipos mejorados de plátanos (Musa spp.)*. Cuba: Facultad de Ciencias Agropecuarias. Universidad Central de las Villas.
- Mountrakis, G., Im, J., y Ogole, C. (2011). Support for integrated analysis of object-based image classification and change detection techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2(66), 247-259.
<https://doi.org/http://dx.doi.org/10.1016/j.isprsjprs.2010.11.001>
- Muñoz-Huerta, R. L., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Torres-Pacheco, I., Prado-Olivarez, J., y Ocampo-Velazquez, R. V. (2013). A review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. *Sensors*, 13(8), 10823-10843. <https://doi.org/https://doi.org/10.3390/s130810823>
- Mutanga, O., Skidmore, A. K., y Prins, H. T. (2004). Predicting in situ pasture quality in the Kruger National Park, South Africa, using continuum-removed absorption features. *Remote Sensing of Environment*, 89(3), 393-408.
<https://doi.org/https://doi.org/10.1016/j.rse.2003.11.001>
- Mutanga, O., y Skidmore, A. K. (2007). Red edge shift and biochemical content in grass canopies. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1(62), 34-42.
<https://doi.org/https://doi.org/10.1016/j.isprsjprs.2007.02.001>
- Nath, M., Bhatt, D., Prasad, R., Gill, S. S., Anjum, N. A., y Tuteja, N. (2016). Reactive oxygen species (ROS) metabolism and plant mineral nutrition. En N. Tuteja, y S. S. Gill, *Crop Improvement Under Adverse Conditions* (pp. 227-245). Springer.
- Numata, I., Soares, J. V., Roberts, D. A., Fontes, P. R., Calheiros, D. F., y Barr, J. R. (2018). Evaluation of pasture nutrient status using remote sensing techniques. *Journal of Plant Nutrition*, 10(31), 1860-1872.
- Omer, G., Mutanga, O., Abdel-Rahman, E. M., y Ismail, R. (2015). Exploring the operational utility of CBERS-2 image products for ozometric monitoring of savanna vegetation: A

case study from KwaZulu-Natal, South Africa. *Journal of Applied Remote Sensing*, 9(1), 096087.

Ortíz, G. G. (2004). *Aplicación de prácticas de conservación de suelo para la siembra de piña en Ladera. CORPOICA, CVC. Palmira: CORPOICA. , de. Ecuador:*
<https://books.google.com.ec/books?id=m-Le3FoQx3kC&pg=PA7&dq=Aplicacion+edafica+de+fertilizantes&hl=es&sa=X&ved=0ahUKEwj8qa457XJAhUDmx4KHfPwA2cQ6AEIjAC#v=onepage&q=Aplicacion%20edafica%20de%20fertilizantes&f=false>.

Osborne, S. L., Schepers, J. S., Francis, D. D., y Schlemmer, M. R. (2002). Use of spectral radiance to estimate in-season biomass and grain yield in nitrogen-and water-stressed corn. *Crop Science*, 42(1), 165-171.
<https://doi.org/https://doi.org/10.2135/cropsci2002.1650>

Palomino, A. (2015). *Agricultura Alternativa: Principios*. Bogota, Colombia: San Pablo:
<https://books.google.com.ec/books?id=BoSUZ6-ieVoC&pg=PA30&dq=fertilizacion+alternativa&hl=es&sa=X&ved=0ahUKEwj2yum08LjJAhWBFR4KHfNQBC8Q6AEIGjAA#v=onepage&q&f=false>.

Paredes, F., Padilla, J., Mollocana, C., y Gómez, P. (2020). Detección de deficiencias de nitrógeno en cultivos de papa (*Solanum tuberosum*) mediante imágenes multiespectrales adquiridas con vehículos aéreos no tripulados (UAV). *Revista Ibérica de Sistemas e Tecnologías de Informação*, E29, 406-419.

Parraga, B. (2016). *MÉTODOS Y NIVELES DE FERTILIZACIÓN DEL PLÁTANO BARRAGANETE, EN LA EXPORTACIÓN Y EFICIENCIA DE NUTRIENTES*. Trabajo de Titulación

Peñuelas, J., Filella, I., Biel, C., Serrano, L., y Save, R. (1993). The reflectance at the 950–970 nm region as an indicator of plant water status. *International Journal of Remote Sensing*, 14(10), 1887-1905.
<https://doi.org/https://doi.org/10.1080/01431169308954010>

- Pimstein, A., Karnieli, A., Bansal, S. K., y Bonfil, D. J. (2011). Exploring remotely sensed technologies for monitoring wheat potassium and phosphorus using field spectroscopy. *Field Crops Research*, 121(1), 125-135.
<https://doi.org/https://doi.org/10.1016/j.fcr.2010.12.001>
- PROEcuador. (2015). *Análisis Sectorial Plátano Análisis sectorial, Instituto de promoción de exportaciones e inversiones, Quito*. Ecuador: http://www.proecuador.gob.ec/wp-content/uploads/2015/06/PROEC_AS2015_PLATANO1.pdf .
- PROEcuador. (2015). *Análisis Sectorial Plátano. Análisis sectorial, Instituto de promoción de exportaciones e inversiones*. http://www.proecuador.gob.ec/wp-content/uploads/2015/06/PROEC_AS2015_PLATANO1.pdf
- Pullanagari, R. R., Pullanagari, I. J., Tuohy, M. P., Hedley, M. J., Dynes, R. A., y King, W. M. (2012). In-field hyperspectral proximal sensing for estimating quality parameters of mixed pasture. *Precision Agriculture*, 13(3), 351-369.
<https://doi.org/https://doi.org/10.1007/s11119-011-9251-4>
- Qixing, Z., y Jide, H. (2019). Sampling design for an area frame based on drone remote sensing images. *Remote Sensing*, 11(16), 1-22.
- Quintero, R. (1995). Fertilización y Nutrición. *El cultivo de la caña en la zona azucarera de Colombia, Cali, CENICAÑA*, 153-177.
- Quintero, R. (1998). *Fertilización y Nutrición en plátano*. Colombia.
- Quintero, R. (2005). *Fertilización y Nutrición, El Cultivo de la Caña en la Zona Azucarera de Colombia*. Cali-Colombia:
https://www.cenicana.org/pdf_privado/documentos_no_seriadados/libro_el_cultivo_cana/libro_p3-394.pdf.
- Ramírez, J., Cuervo, J. L., y Cuesta, P. A. (2019). Efecto de la aplicación de dosis de cal en un oxisol de la Amazonía ecuatoriana sobre el rendimiento y calidad nutricional de *Brachiaria decumbens*. *Livestock Research for Rural Development*, 31(8), #138.
- Rao, I. M., Kerridge, P. C., y Macedo, M. M. (1996). Requerimientos nutricionales del género

- Brachiaria y adaptación a los suelos ácidos. En J. W. Miles, B. L. Maass, y C. B. do Valle, (Eds.), *Brachiaria: Biología, Agronomía y Mejoramiento* (pp. 53-71). CIAT/EMBRAPA.
- Riaño, D., Chuvieco, E., Salas, J., y Aguado, I. (2003). Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types. *IEEE Transactions on Geoscience and Remote Sensing*, 41(5), 1056-1061.
- Richter, R. (1996). Atmospheric correction of satellite data with haze removal including a haze/clear transition region. *Computers & Geosciences*, 22(6), 675-681.
[https://doi.org/https://doi.org/10.1016/0098-3004\(96\)00010-6](https://doi.org/https://doi.org/10.1016/0098-3004(96)00010-6)
- Rodríguez, M. (1985). *Producción de plátano (Musa AAB)*. [https://books.google.com.ec > books](https://books.google.com.ec/books).
- Rodríguez, M. (2017). *INFLUENCIA DE TRESNIVELES DE CARBAMIDASOBRE LA INDUCCIÓN DE HIJUELOS DE PLÁTANO (Musa aabsimmonds)EN EL VALLE DEL RÍO CARRIZAL*. <http://repositorio.esпам.edu.ec/handle/42000/539>
- Romero, V. (1982). *Técnicas de aplicación de fertiizantes*.
[https://repository.agrosavia.co>bitstream>handle](https://repository.agrosavia.co/bitstream/handle)
- Rouse, J. W., Haas, R. H., Schell, J. A., y Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. En S. C. Freden, E. P. Mercanti, y M. A. Becker, (Eds.), *Third Earth Resources Technology Satellite-1 Symposium* (pp. 309-317). NASA.
- Salach, A., Bakuła, K., Pilarska, M., Ostrowski, W., Górski, K., y Kurczyński, Z. (2018). Aplicación de drones para evaluar el diámetro de copas en masas forestales utilizando un sistema LiDAR-computadora. *Remote Sensing*, 4(10), 587.
<https://doi.org/https://doi.org/10.3390/rs10040587>
- Sanchez, J. (2012). *Metodologia de la investigacion cientifica y tecnologica*.
[https://es.scribd.com > document > Metodologia-de-la-Investigacion-Cientifica-y-](https://es.scribd.com/document/Metodologia-de-la-Investigacion-Cientifica-y-)

Tecnologica.pdf

- Sancho, H. (1999). *Curvas de absorción de nutrientes: importancia y uso en los programas de fertilización*. Informaciones Agronómicas: [inranet.exa.unne.edu.ar>biologia>fisiologia.vegetal>Curva de absorcion de nutrientes](http://inranet.exa.unne.edu.ar/biologia/fisiologia/vegetal/Curva_de_absorcion_de_nutrientes)
- Sanz-Abajnides, P., Ferrone, A., Fernández-Quintanilla, C., Andújar, D., Dorado, J., y Jesús, R. (2019). Mapeo de malas hierbas de girasol tempranas mediante fotogrametría aérea de drones de bajo coste. *Revista Internacional de Sensores Remotos*, 19(40), 7516-7535. <https://doi.org/https://doi.org/10.1080/01431161.2019.1617102>
- Schellberg, J., Hill, M. J., Gerhards, R., Rothmund, M., y Braun, M. (2008). Precision agriculture on grassland: Applications, perspectives and constraints. *European Journal of Agronomy*, 2-3(29), 59-71. <https://doi.org/https://doi.org/10.1016/j.eja.2008.05.005>
- Serbin, G., Townsend, P. A., Pereira, R., y Menges, C. H. (2015). Discriminación de hábitats tropicales usando datos de reflectancia de hojas e imágenes hiperespectrales obtenidas desde drones. *Remote Sensing*, 9(7), 11242-11266. <https://doi.org/https://doi.org/10.3390/rs70911242>
- Serrano, J. M., Peça, J. O., Marques da Silva, J. R., Shaidian, G., y Moghaddam, S. S. (2018). Evaluación del estado nutricional del pasto mediante imágenes espectrales de drones y análisis de índices de vegetación. *Revista Internacional de Sensores Remotos*, 23(39), 8859-8872.
- Siebert, S., y Teizer, J. (2014). Fotogrametría móvil: una técnica de mapeo económica para grandes áreas en tierra. *Revista de Ingeniería de Visualización*, 2(16), 145, 173. <https://doi.org/https://doi.org/10.1007/s12650-014-0212-0>
- Sims, D. A., y Gamon, J. A. (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 2-3(81), 337-354. [https://doi.org/https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/https://doi.org/10.1016/S0034-4257(02)00010-X)

- Skerman, P. J., y Riveros, F. (1990). *Gramíneas tropicales*. FAO.
- Skidmore, A. K., Ferwerda, J. G., Mutanga, O., Van Wieren, S. E., Peel, M., Grant, R. C., . . . Venus, V. (2010). Monitoreo de la recuperación de la vegetación después de la aplicación de fertilizantes minerales utilizando imágenes hiperespectrales. *Revista Internacional de Sensores Remotos*, 24(31), 6545-6560.
- Slaughter, C. D., Henley, R. W., Roberts, C. M., West, L., y Tang, X. P. (2008). Discriminant analysis of iron stress in corn plants by pattern recognition using spectral data in the visible and near-infrared regions. *Transactions of the ASABE*, 51(4), 1313-1319.
- Snyder, C. &. (2015). *Nutrient Use Efficiency and Effectiveness in North America: Indices of Agronomic and Environmental Benefit*. Estados Unidos: International Plant Nutrition.
- Somers, B., Asner, G. P., Tits, L., y Coppin, P. (2011). Endmember variability in spectral mixture analysis: A review. *Remote Sensing of Environment*, 115(7), 1603-1616.
<https://doi.org/https://doi.org/10.1016/j.rse.2011.03.003>
- Stewar, W. (2007). *Consideraciones del uso eficiente de nutrientes*. Colombia.
- Stewar, W. (2011). *IPNI - North Latin America*. Recuperado el 20 de Enero de 2015, de *International Plant Nutrition Institute*:. IPNI - North Latin America. Recuperado el 20 de Enero de 2015, de International Plant Nutrition Institute:.
[http://nla.ipni.net/ipniweb/region/nla.nsf/e0f085ed5f091b1b852579000057902e/40ad1eee26c802f005257a5300510c6d/\\$FILE/ATTCNQIX](http://nla.ipni.net/ipniweb/region/nla.nsf/e0f085ed5f091b1b852579000057902e/40ad1eee26c802f005257a5300510c6d/$FILE/ATTCNQIX).
- Tegeder, M., y Masclaux-Daubresse, C. (2018). Mecanismos fuente y sumidero del transporte y uso del nitrógeno. *New Phytologist*, 217(1), 35-53.
<https://doi.org/https://doi.org/10.1111/nph.14876>
- Tian, Y. C., Yao, X., Yang, J., Cao, W. X., Hannaway, D. B., y Zhu, Y. (2011). Monitoreo de deficiencia de nitrógeno en pastos de alfalfa mediante imágenes de satélite de alta resolución. *Revista Internacional de Sensores Remotos*, 24(32), 9619-9631.
- Tilly, N., Aasen, H., y Bareth, G. (2015). Identificación de deficiencias de potasio en plantas

de trigo utilizando imágenes hiperespectrales. *Revista Internacional de Sensores Remotos*, 1(36), 26-40.

Torres, B. (2006). *Metodología de la Investigación*. abacoenred.com>el-proyecto-de-investigacion-FG-Arias-2012-pdf.pdf

Torres-Sánchez, J., Peña, J. M., de Castro, A. I., y López-Granados, F. (2018). Aplicación multi-temporal de procesamiento de imágenes de drones para la detección de cultivos tempranos en agricultura de precisión. *Remote Sensing*, 9(10), 1350.
<https://doi.org/https://doi.org/10.3390/rs10091350>

Tsay, Y.-F., Chiu, C.-C., Tsai, C.-B., Ho, C.-H., y Hsu, P.-K. (2007). Nitrate transporters and peptide transporters. *FEBS Letters*, 581(12), 2290-2300.
<https://doi.org/https://doi.org/10.1016/j.febslet.2007.04.047>

Tumbaco, A. P. (2012). *Manual del cultivo de platano de exportacion*. ESPE Santo Domingo: <http://giat.espe.edu.ec/wp-content/uploads/2012/12/Outline-del-libro.pdf>

Tumbaco., A., Patiño, M., Tumbaco, J., y Ulloa, S. (2012). *Manual del cultivo de plátano de exportación*. Ecuador: <http://giat.espe.edu.ec/wp-content/uploads/2012/12/outline-del-libro.pdf>.

Tumbaco., e. a., Patiño, M., Tumbaco, J., y Ulloa, S. (2012). *Manual del cultivo de plátano de exportación*. Ecuador: <http://giat.espe.edu.ec/wp-content/uploads/2012/12/outline-del-libro.pdf>.

Vaca, D. C. (2008). *Evaluacion de varios niveles de de fertilizacion en aplicacion edáfica y en fertirriego en el cultivo de platano (Musa AAB)*. Ecuador: Fertirriego de platano en Ecuador.

Vaca., D. C. (2008). *Evaluación de Varios Niveles de Fertilización en Aplicación Edáfica y en Fertirriego en el Cultivo de Plátano (Musa AAB Simmonds)*. El Carmen. Manabí. Ecuador: <file:///C:/Users/HP/AppData/Local/Temp/41-Texto%20del%20art%C3%ADculo-68-1-10-20170914.pdf>.

- Valdiviezo, F. (2014). *APLICACIÓN DE SOLUCIONES NUTRITIVAS INYECTADAS Y EN DRENCH MÁS LA ADICIÓN DE LEONARDITA EN EL CULTIVO DE BANANO (Musa AAA.) VARIEDAD WILLIAMS*". repositorio.ug.edu.ec › bitstream › redug › URBANViejoNESTOR
- Vance, C. P., Uhde-Stone, C., y Allan, D. L. (2003). Phosphorus acquisition and use: Critical adaptations by plants for securing a nonrenewable resource. *New Phytologist*, 157(3), 423-447. <https://doi.org/https://doi.org/10.1046/j.1469-8137.2003.00695.x>
- Villalobos, L., y Arce, J. (2014). Fertilización de pasturas con otros nutrientes diferentes al nitrógeno. En J. C. Burkart, y Z. Gaggioli, *Producción y utilización de pasturas* (pp. 117-146). Instituto Nacional de Innovación y Transferencia en Tecnología Agropecuaria.
- Villalobos, L., y Ritchie, J. C. (2018). Efecto de la deficiencia nutricional en la reflectancia espectral y el rendimiento de biomasa de Brachiaria híbridos. *Revista Internacional de Sensores Remotos*, 15-16(39), 5004-5023.
- Villareal, J. E. (2012). *Monitoreo de cambios en la fertilidad de suelos por medio de análisis de laboratorio*. Costa Rica: <https://www.redalyc.org/pdf/437/43724664009.pdf>.
- Villarroel, C. R. (2015). *FERTILIZACIÓN FOLIAR COMPLEMENTARIA PARA NUTRICION Y SANIDAD EN PRODUCCION DE PAPAS*. Ecuador: <http://www.jadefo.org.mx/jwp/wp-content/uploads/Fertilizacion.pdf>. www.jadefo.org.mx/jwp/wp-content/uploads/Fertilizacion.pdf
- Vivas, J. (2017). *Fertilización del plátano con nitrógeno, fósforo y potasio en cultivo establecido*. <https://dialnet.unirioja.es>
- Yepez, J. C. (2015). *EFFECTO DE ALTAS DENSIDADES Y DOS SISTEMAS DE SIEMBRA SOBRE EL RENDIMIENTO Y RENTABILIDAD DEL CULTIVO DE PLÁTANO (Musa AAB) BAJO CONDICIONES DE REGADÍO*". Ecuador: <https://repositorio.uteq.edu.ec/bitstream/43000/23/1/T-UTEQ-0009.pdf>.

- Young, S., Bhatti, T., Loechl, P., y Boscia, D. (1997). Brdf correction for imaging spectrometers. *Fifth JPL Annual Airborne Earth Science Workshop*. Pasadena, CA.
- Zambrano, Y. M. (2018). *Niveles de fertilizacion en la Morfologia, produccion y calidad del platano dominico harton (Mussa AAB)*. Ecuador:
<https://repositorio.uleam.edu.ec/bitstream/123456789/93/1/ULEAM-AGRO-0009.pdf>.
- Zarco-Tejada, P. J., González-Dugo, V., y Berni, J. J. (2013). Fluorescencia inducida por el láser, las características de la vegetación y la detección de estrés por agua. *Revista Internacional de Sensores Remotos*, 5(33), 1492-1509.
<https://doi.org/https://doi.org/10.1080/01431161.2011.606027>

ANEXOS

Anexo 1. ADEVA de la variable altura de la planta

F.V.	SC	gl	CM	F	Valor p	Rangos
Total	1,02	20				
Tratamiento	0,8	6	0,13	8,97	0,0007	**
Factor A	0,07	1	0,07	6,42	0,0297	*
Factor B	0,24	2	0,12	11,01	0,003	**
Factor A*Factor B	0,01	2	0	0,37	0,7026	N/S
Tratamientos vs Testigo	0,48	1	0,48	32,11	0,0001	**
Repetición	0,04	2	0,02	1,45	0,2734	
Error	0,18	12	0,01			
CV	3,17					

Anexo 2. Hojas foliares de la planta de pasto *Brachiaria*



Anexo 3. *Dron Autel Evo 2 Pro 6k*





TESIS act BBT0 PESANTEZ (2)-1

2%
Textos sospechosos

16% Similitudes (ignorado)
< 1% similitudes entre comillas
3% entre las fuentes mencionadas
2% Idiomas no reconocidos

Nombre del documento: TESIS act BBT0 PESANTEZ (2)-1.docx
ID del documento: d8510ebacff8677147619212ab1d79cf1160621e
Tamaño del documento original: 1,13 MB

Depositante: FRANCEL LOPEZ MEJIA
Fecha de depósito: 31/7/2024
Tipo de carga: interface
fecha de fin de análisis: 31/7/2024

Número de palabras: 16.027
Número de caracteres: 115.646

Ubicación de las similitudes en el documento:



Fuentes principales detectadas

Nº	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	Pinargote Yuliana tesis antiplagio.docx Pinargote Yuliana tesis antiplagio #4823b4 El documento proviene de mi grupo 16 fuentes similares	8%		Palabras idénticas: 8% (1067 palabras)
2	repositorio.uileam.edu.ec https://repositorio.uileam.edu.ec/bitstream/123456789/4617/1/UILEAM-AGRO-0137.pdf 16 fuentes similares	8%		Palabras idénticas: 8% (1172 palabras)
3	repositorio.uileam.edu.ec https://repositorio.uileam.edu.ec/bitstream/123456789/5213/1/UILEAM-AGRO-0308.PDF 15 fuentes similares	8%		Palabras idénticas: 8% (1153 palabras)
4	Tesis Anthony Vega.docx Tesis Anthony Vega #00e9f3 El documento proviene de mi grupo 5 fuentes similares	3%		Palabras idénticas: 3% (346 palabras)
5	NALLELY TESIS-2.docx NALLELY TESIS-2 #d83cf9 El documento proviene de mi biblioteca de referencias 4 fuentes similares	2%		Palabras idénticas: 2% (323 palabras)

Fuentes con similitudes fortuitas

Nº	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	www.doi.org https://www.doi.org/10.1007/s10661-016-5126-5	< 1%		Palabras idénticas: < 1% (37 palabras)
2	dialnet.unirioja.es https://dialnet.unirioja.es/descarga/articulo/3178816.pdf	< 1%		Palabras idénticas: < 1% (40 palabras)
3	riaa.uaem.mx http://riaa.uaem.mx/xmlui/bitstream/20.500.12055/1896/1/MERTFD09T.pdf	< 1%		Palabras idénticas: < 1% (37 palabras)
4	www.doi.org https://www.doi.org/10.1590/0034-737X201966020009	< 1%		Palabras idénticas: < 1% (35 palabras)
5	doi.org In-field hyperspectral proximal sensing for estimating quality parameters... https://doi.org/https://doi.org/10.1007/s11119-011-9251-4	< 1%		Palabras idénticas: < 1% (37 palabras)

Fuentes mencionadas (sin similitudes detectadas)

 Estas fuentes han sido citadas en el documento sin encontrar similitudes.

- <https://doi.org/https://doi.org/10.1080/01431161.2016.1264032>
- <https://doi.org/https://doi.org/10.3390/rs9111144>
- <https://www.redalyc.org>
- <https://repositoriotec.ac.cr>
- <http://www.mag.go.cr/bibliotecavirtual/a00082.pdf>