

**ESTIMACIÓN DE NITRÓGENO EN DOSEL PARA EL CULTIVO DE CAÑA DE
AZÚCAR (*Saccharum Offcinarum*) A PARTIR DE IMÁGENES
MULTIESPECTRALES.**



Autores

EDUARDO JOSÉ SAIZ ALVAREZ.

1723524

JOSE ALEJANDRO MORENO MAYA

1922833

**Trabajo de grado para optar por el título de Ingeniero Agrícola e Ingeniero
Topográfico.**

Director: Aldemar Reyes Trujillo

Docente Facultad de Ingeniería Universidad del Valle

Director: Cesar Edwin García

Docente Facultad de Ingeniería Universidad del Valle

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERIA
ESCUELA DE INGENIERÍA DE RECURSOS NATURALES Y DEL AMBIENTE -
EIDENAR
PROGRAMA ACADÉMICO DE INGENIERÍA AGRÍCOLA - PAIA
ESCUELA DE INGENIERÍA CIVIL Y GEOMATICA
PROGRAMA ACADÉMICO DE INGENIERÍA GEOMATICA - PAIG
CALI - VALLE DEL CAUCA
2025**

Tabla de contenido

AGRADECIMIENTOS.....	10
RESUMEN.....	11
1. INTRODUCCIÓN.....	12
2. PLANTEAMIENTO DEL PROBLEMA.....	14
3. JUSTIFICACIÓN.....	15
4. OBJETIVOS.....	18
4.1. Objetivo general:	18
4.2. Objetivos específicos:.....	18
5. REVISIÓN DE LITERATURA.....	19
5.1. Marco conceptual.....	19
5.1.1. Caña de azúcar:	19
5.1.2. Etapas fenológicas:	20
5.1.3. Nitrógeno:.....	20
5.1.4. Espectro electromagnético:	21
5.1.5. Espectroscopia óptica:.....	21
5.1.6. Índice de vegetación:.....	21
5.1.6.1. Índice de hoja verde (GLI):	22
5.1.6.2. Índice de vegetación ajustado al suelo optimizado (GOSAVI):	22
5.1.6.3. Índice de vegetación de diferencia normalizada (NDVI):	22
5.1.6.4. Índice de vegetación de diferencia normalizada verde (GNDVI):	22
5.1.6.5. Índice de vegetación de diferencia renormalizada (RDVI):	22
5.1.6.6. Índice de vegetación mejorado (EVI):.....	22
5.1.6.7. Índice de vegetación óptimo (VI_{OPT}):.....	22
5.1.6.8. Índice normalizado diferencial de borde rojo (NDRE):	23
5.1.6.9. Índice de vegetación de diferencia normalizada azul (BNDVI):	23
5.1.6.10. Índice de coloración o índice de clorofila (CI):	23
5.1.6.11. Índice de clorofila verde (CI _{Green}):	23
5.1.6.12. Índice de vegetación de clorofila (CVI):.....	23
5.1.6.13. Índice de clorofila Rojo cercano (CI _{rededge}):	23
5.1.6.14. Índice de vegetación de diferenciar normalizada mejorada (ENDVI):	24
5.1.6.15. Índice de exceso de verde (ExG):	24
5.1.6.16. Índice de diferencia normalizada verde – rojo (NGRDI):	24
5.1.6.17. Índice de diferencia normaliza (NDI):.....	24
5.1.6.18. Índice de contenido de clorofila del dosel (CCCI):	24

5.1.6.19.	<i>Índice de resistencia atmosféricamente visible (VARI):</i>	24
5.1.6.20.	<i>Índice de vegetación transformado (TVI):</i>	24
5.1.6.21.	<i>Índice de vegetación ajustada de suelos modificado (MSAVI):</i>	24
5.1.6.22.	<i>Índice verde triangular (TGI):</i>	25
5.1.6.23.	<i>Índice de diferencia normalizada borde rojo – verde (GNDRE):</i>	25
5.1.7.	<i>Teledetección:</i>	25
5.1.8.	<i>Matriz de co-ocurrencia de nivel de gris (GLCM):</i>	25
5.1.9.	Descriptores de texturas de la matriz de co-ocurrencia:	26
5.1.10.	Ground Sampling Distance (GSD):	27
5.1.11.	Real Time Kinematic (RTK):	27
5.1.12.	Correlación de Spearman:	27
5.1.13.	Regresión por mínimos cuadrados parciales (PLS):	27
5.1.14.	Desviación residual predictiva (RPD):	28
5.1.15.	Importancia de la variable en la proyección (VIP):	28
5.2.	Marco de antecedentes	28
5.3.	Marco Teórico	31
5.3.1.	Contenido de nitrógeno en el dosel:	31
5.3.2.	Índice de textura de diferencia normalizada (NDTI):	31
5.3.4.	Error medio cuadrático y error medio cuadrático relativo:	32
5.3.5.	Correlación de Spearman (RHO):	32
5.3.6.	Regresión de minimos cuadrados parciales (PLS):	33
6.	METODOLOGÍA	36
6.1.	Ruta metodológica del proyecto.	36
6.2.	Antecedente.	36
6.3.	Plan de vuelo.	39
6.4.	Materiales y métodos:	40
6.4.1.	Sistema:	40
6.5.	Metodología objetivo específico 1:	41
6.5.1.	Procesamiento de imágenes multiespectrales en Agisoft Metashape...	41
6.5.2.	Procesamiento de ortomosaicos en ENVI para la GLCM	42
6.5.3.	Extracción de información espectral:	44
6.5.4.	Cálculo de los índices espectrales:	44
6.6.	Metodología objetivo específico 2:	45
6.7.	Metodología objetivo específico 3:	46
7.	RESULTADOS Y DISCUSIÓN	48
7.1.	Procesamiento de imágenes multiespectrales.	48

7.1.1.	Verificación de imágenes multiespectrales	48
7.1.2.	Construcción de ortomosaicos en valores de reflectancia con Agisoft Metashape.	49
7.1.3.	Georreferenciación de los ortomosaicos	50
7.1.4.	Estimación de valores de textura con ENVI.	51
7.1.5.	Extracción de valores digitales de las campañas y construcción de base de datos	53
7.2.	Correlación de Spearman	55
7.3.	Modelo PLS entre índices espectrales y Nitrógeno.	59
7.4.	Coeficientes de regresión del modelo.	62
7.5.	Importancia de la variable en la proyección para el modelo PLS.	65
8.	CONCLUSIONES	69
9.	RECOMENDACIONES	70
10.	REFERENCIAS BIBLIOGRÁFICAS	71
11.	ANEXOS	85

LISTA DE TABLAS

Tabla 1	Antecedentes relacionados con espectroscopía, nitrógeno y caña de azúcar.....	29
Tabla 2	Listado de índices vegetativos	34
Tabla 3	Características edáficas de la estación experimental.....	37
Tabla 4	Características del montaje experimental	38
Tabla 5	Rangos para la correlación de Spearman.	46
Tabla 6	Métricas para evaluar el rendimiento del modelo	46
Tabla 7	Correlación de Spearman (Nitrógeno vs Índices espectrales) en campaña 1.....	56
Tabla 8	Resultados significativos en el ciclo de plantilla	57
Tabla 9	Resultados significativos en el ciclo de soca.....	57
Tabla 10	Resultados del modelo en el ciclo de plantilla.....	61
Tabla 11	Resultados del modelo en el ciclo de soca	61
Tabla 12	Coeficientes de regresión significativos en el ciclo de plantilla.....	63
Tabla 13	Coeficientes de regresión significativos en etapa de soca	64
Tabla 14	Interpretación VIP	65
Tabla 15	Resultados significativos VIP en el ciclo de plantilla.....	67
Tabla 16	Resultados significativos VIP en el ciclo de soca	67

LISTA DE FIGURAS

Figura 1 Principales departamentos productores de caña de azúcar y las condiciones edafoclimáticas óptimas para el cultivo	15
Figura 2 Cultivo de caña de azúcar	19
Figura 3 Etapas fenológicas en el cultivo de caña de azúcar	20
Figura 4 Espectro electromagnético	21
Figura 5 Ruta metodológica	36
Figura 6 Localización de la zona de estudio	37
Figura 7 Distribución experimental	38
Figura 8 Líneas de cultivo del diseño experimental	39
Figura 9 Levantamiento RTK en el diseño experimental	40
Figura 10 Diagrama de flujo - procesamiento de las imágenes multiespectrales en Agisoft Metashape	42
Figura 11 Diagrama de flujo - procesamiento de los ortomosaicos en ENVI	43
Figura 12 (a) Panel de calibración de la cámara (b) Cultivo en ciclo de soca.	48
Figura 13 Procesamiento en Agisoft Metashape campaña en ciclo de plantilla	49
Figura 14 Representación color verdadero postprocesamiento en Agisoft	50
Figura 15 Georreferenciación en ArcGIS.....	50
Figura 16 Zoom a los puntos de control en la campaña	51
Figura 17 Filtro de textura en ENVI	51
Figura 18 Parámetros de textura en ENVI.....	52
Figura 19 Creación de sub-escena.....	52
Figura 20 Bandas obtenidas después del procesamiento en ENVI	53
Figura 21 Creación de puntos en QGIS para el ciclo de plantilla.....	54
Figura 22 Creación de puntos en QGIS para el ciclo de soca	54
Figura 23 Datos de todas las campañas del año 2019 (ciclo de soca)	55
Figura 24 Promedio de los índices por campañas (ciclo de soca)	55
Figura 25 RMSEnormalizado vs Número de componentes (a) campaña 1 (b) campaña 2 (c) campaña 3 y (d) campaña 4.....	60
Figura 26 RMSEnormalizado vs Número de componentes (a) campaña 5 (b) campaña 6 (c) campaña 7 y (d) campaña 8.....	60
Figura 27 Coeficientes de regresión en etapa de plantilla (a) campaña 1 (b) campaña 2 (c) campaña 3 (d) campaña 4	62
Figura 28 Coeficientes de regresión en etapa de soca (a) campaña 5 (b) campaña 6 (c) campaña 7 (d) campaña 8	63
Figura 29 Importancia de la variable en la proyección en la etapa de plantilla (a) campaña 1 (b) campaña 2 (c) campaña 3 (d) campaña 4	66
Figura 30 Importancia de la variable en la proyección en la etapa de soca (a) campaña 5 (b) campaña 6 (c) campaña 7 (d) campaña 8.....	66

LISTA DE ANEXOS

Anexo 1	Correlación de Spearman por campaña en etapa de plantilla.....	85
Anexo 2	Correlación de Spearman por campaña en etapa de soca.....	85
Anexo 3	Código PLS en R.....	85
Anexo 4	Código correlación de Spearman en R.....	85
Anexo 5	Calculo de índices en etapa de plantilla.....	85
Anexo 6	Calculo de índices en etapa de soca.....	85
Anexo 7	Resultados generales en etapa de plantilla.....	85
Anexo 8	Resultados generales en etapa de soca	85

LISTA DE ABREVIATURAS

N: Nitrógeno

Nc: Nitrógeno en dosel

IV: Índices de vegetación

AEPS: Agricultura específica por sitio

PLS: Regresión por mínimos cuadrados parciales (En inglés: Partial Least Squares)

UAV: Vehículo aéreo no tripulado

RPAS: Sistema de aeronave pilotada remotamente

GSD: Ground Sampling Distance

RTK: Real time kinematic

GLI: Índice de hoja verde

GOSAVI: Índice de vegetación ajustado al suelo optimizado

NDVI: Índice de vegetación de diferencia normalizada

GNDVI: Índice de vegetación de diferencia normalizada verde

RDVI: Índice de vegetación de diferencia renormalizada

EVI: Índice de vegetación mejorado

VI_{OPT}: Índice de vegetación óptimo

NDRE: Índice normalizado diferencial de borde rojo

BNDVI: Índice de vegetación de diferencia normalizada azul

CI: Índice de coloración

CI_{Green}: Índice de clorofila verde

CVI: Índice de clorofila en vegetación

CI_{rededge}: Índice de clorofila borde rojo

ENDVI: Índice de vegetación de diferencia normalizada mejorada

ExG: Índice de exceso de verde

NGRDI: Índice de diferencia normalizada rojo – verde

NDI: Índice de diferencia normalizada

TGI: Índice triangular verde

GNDRE: Índice de diferencia normalizada borde rojo - verde

MSAVI: Índice de vegetación ajustada al suelo modificado

TVI: Índice de vegetación transformada

VARI: Índice de resistencia atmosférica

CCCI: Índice de contenido de clorofila en el dosel

VIP: Importancia de la variable en la proyección

RPD: Desviación residual predictiva

IAF: Índice de área foliar

DDS: Días después de la siembra

DDC: Días después de la cosecha

AGRADECIMIENTOS

Este trabajo es el fruto del apoyo y colaboración de varias personas. Agradecemos a nuestros padres por estos años de amor, cuidados y paciencia, porque son nuestra fuente de motivación e inspiración. A Dios por todas las bendiciones que hemos recibido a lo largo de nuestra formación como profesionales y todo nuestro núcleo familiar en general porque también fueron parte esencial de nosotros en todos los ámbitos.

Profunda gratitud a los profesores Aldemar Reyes Trujillo y Cesar Edwin García Cortes por todo el compromiso y acompañamiento brindado a lo largo del desarrollo de este trabajo de grado.

Al Centro de Investigación de la Caña de Azúcar de Colombia (Cenicaña) por brindarnos el material para llevar a cabo nuestra investigación.

RESUMEN

Conocer el estado nutricional de las plantas, especialmente el contenido de nitrógeno es fundamental en la agricultura para la planificación de la fertilización nitrogenada en cultivos como la caña de azúcar en el Valle del Cauca. Este proyecto tiene como propósito desarrollar un modelo de estimación de la concentración de nitrógeno en dos ciclos del cultivo (plantilla y soca) de caña de azúcar variedad CC-01-1940 sometido a diferentes dosis de fertilización nitrogenada.

Se obtuvo información multiespectral y de la concentración de nitrógeno foliar a partir de cuatro campañas de medición por ciclo. Para la construcción del modelo de regresión por mínimos cuadrados parciales (PLS), se procesaron las imágenes multiespectrales y se obtuvieron 23 índices de vegetación (IV), adicionalmente, mediante una matriz de coocurrencia de niveles de grises se calcularon 8 variantes de textura para cada uno de los IV, para un total de 207 variables predictoras.

Dando como resultado que el modelo es más útil para estimar el contenido de nitrógeno en etapas tempranas de desarrollo vegetativo ($R^2 > 0.756$) en caña de azúcar, específicamente en la variedad CC 01-1940, logrando identificar mayor influencia en la predicción del modelo en índices espectrales que involucran la región del rojo, borde rojo e infrarrojo cercano (RedEdge & NIR).

Palabras clave: PLS, Nitrógeno, Índices espectrales, Agricultura, Multiespectral.

1. INTRODUCCIÓN

En el sector agrícola es de gran interés desarrollar técnicas para estimar variables fotoquímicas, producción y rendimiento de diferentes cultivos. En grandes extensiones, contar con esta información puede ser costoso (Filla et al., 2023). En consecuencia, es importante establecer metodologías que permitan el monitoreo agrícola de una forma eficiente.

Los índices espectrales son combinaciones de reflectancia espectral de dos o más longitudes de onda que indican la abundancia relativa de características de interés. Los índices de vegetación son el tipo más popular, pero hay otros índices disponibles para áreas quemadas, elementos creados por el hombre (construidos), agua y elementos geológicos (Xue & Su, 2017).

Existe un vasto potencial para la aplicación de índices de vegetación en la agricultura, que se constituyen en modelos matemáticos, basados en el análisis espectral de ondas electromagnéticas que presentan la capacidad de un estudio rápido del estado de las plantas en grandes áreas de cultivo (Xue et al., 2008; Marcussi et al., 2010).

En teledetección, el índice de vegetación de diferencia normalizada (NDVI), ha sido ampliamente estudiado para la predicción de la biomasa, la necesidad de fertilización nitrogenada, el rendimiento y otros atributos en cultivos como el trigo (Chang & Huang, 2024; Hassan et al., 2019), el estudio de NDVI en caña de azúcar y en otros cultivos favorece directamente en la toma de decisiones del agricultor, pues permite conocer el estado de salud de las plantas y además da paso a modelos de predicción que se pueden adaptarse tanto a variables biofísicas como fotoquímicas.

Por consiguiente, la investigación a realizar se dará a partir del trabajo previamente desarrollado sobre la estimación del nitrógeno foliar en un cultivo de caña de azúcar (*Saccharum officinarum*) variedad CC-01-1940 mediante el uso de espectroscopia óptica desarrollados por Hurtado & Perafán (2019) y Reyes et al. (2020), con el objetivo de estimar variables fotoquímicas en dicho cultivo bajo diferentes dosis de fertilización nitrogenada, a

partir de imágenes multiespectrales obtenidas con una cámara MicaSense transportada en un sistema de aeronave pilotada remotamente (o por su siglas en inglés RPAS).

2. PLANTEAMIENTO DEL PROBLEMA

El nitrógeno es un elemento esencial para el crecimiento de las plantas ya que la deficiencia de este puede resultar en bajos rendimientos en el cultivo y baja rentabilidad para los agricultores (Filella et al., 1995). Además, es útil como indicador crítico para realizar un diagnóstico temprano del estado de salud de estas (Zheng et al., 2018). Históricamente se han utilizado métodos destructivos, costosos y contaminantes para obtener valores de este elemento esencial, los cuales entregan resultados tardíos y generan pérdidas de material vegetativo (Hurtado & Perafán, 2019). Además, el método tradicional solo obtiene información puntual, de una sola fuente, lo cual dificulta su expansión a escala macro (Li et al., 2023).

Debido al desconocimiento del estado actual del contenido de nitrógeno en las plantas, se produce una aplicación excesiva de fertilizantes nitrogenados que desencadenan impactos ambientales, afectando la calidad de aguas subterráneas por efecto de la lixiviación de nitrato (NO_3^-) sin dejar de lado la contaminación por emisión de gases de efecto invernadero (Li et al., 2007). También se produce proliferación de algas lo que es responsable de la pérdida de la biodiversidad y de la anoxia en cuerpos de agua (Estupiñán & Quesada, 2011).

3. JUSTIFICACIÓN

La caña de azúcar en Colombia representa una de las principales actividades económicas aportando el 2,4% del PIB agrícola, 2,0% del PIB industrial y el 0,6% del PIB total del país, por tanto, es esencial para el desarrollo del país (Asocaña, 2024; Sarasti & Ramírez, 2016).

El sector agroindustrial de la caña impacta positivamente en las actividades económicas del país, impulsando la producción y el empleo, este sector en el año 2016 generó 116.032 empleos directos y 170.660 indirectos según la gran encuesta integrada de hogares (GEIH) del DANE y el cálculo de multiplicadores con la matriz insumo-producto realizado por Fedesarrollo (Fedesarrollo, 2018)

El valle del río Cauca cuenta con 429.000 hectáreas planas de origen aluvial con condiciones edafoclimáticas óptimas para el desarrollo del cultivo de caña de azúcar: 1000 msnm, temperatura de 25 °C, humedad relativa de 75% y precipitación promedio de 1000 mm. En la figura 1, se puede observar las condiciones óptimas para el cultivo de caña de azúcar en Colombia (Fedesarrollo, 2018).




Figura 1 Principales departamentos productores de caña de azúcar y las condiciones edafoclimáticas óptimas para el cultivo **Fuente:** (Finagro, 2018)

En el año 2023 se contó con 240.534 hectáreas de área sembrada con caña de azúcar y 193.003 hectáreas de área cosechada lo que reflejó una producción en promedio de 102.0 toneladas de caña por hectárea (Asocaña, 2024).

La producción de caña fue de 20.9 millones de toneladas, generando 1.96 millones de toneladas de azúcar, 328 millones de litros de bioetanol, 1.8 Gigavatio-Hora (GWh) de energía y 180 mil toneladas de miel en el año 2023 (Asocaña, 2024).

Colombia cuenta con distintos centros de investigaciones, donde se continúan haciendo diversos trabajos, destacando, la zonificación agroecológica para el manejo agronómico del cultivo con enfoque de agricultura específica por sitio (AEPS), fertilización de precisión (tasa fija o tasa variada) y mapas de productividad orientadas a identificar de manera temprana posibles dificultades a lo largo de la producción (Ramirez, 2020).

La caña de azúcar es un cultivo presente en la cultura Vallecaucana con más de 1000 accionistas, 2.750 cultivadores, 3.864 fincas y una organización gremial las cuales han permitido desde hace seis décadas la oportunidad de generar ingresos económicos (Ramirez, 2020).

Por lo anterior, es necesario implementar técnicas de percepción remota las cuales permitan tener en constante monitoreo el estado de las plantas, debido a que la producción de caña de azúcar requiere la integración de nutrientes tales como el nitrógeno, fósforo y potasio, entre otros. Estos elementos se involucran en procesos metabólicos que intervienen en la formación de carbohidratos, siendo un constituyente de la clorofila que a su vez está altamente relacionada con el nitrógeno (Moreno et al., 2016).

Según Inoue et al. (2012) estudios previos han revelado que la medición de reflectancia espectral de alta resolución (detección remota hiperespectral) tiene el potencial para la evaluación de componentes bioquímicos. Debido a la variabilidad espacial y temporal del nitrógeno real presente en las plantas, es fundamental obtener información de las condiciones por etapa fenológica, lo que permite establecer un régimen de fertilización diferenciada por sitio (Stroppiana et al., 2009). Lo que, a su vez se traduce en la adecuada aplicación de fertilizantes y reducción de costos, en consecuencia, mejores rendimientos del cultivo.

La clorofila en el cultivo de caña de azúcar es un indicador de la actividad fotosintética de la planta por lo cual guarda una estrecha relación con el estado fenológico y la salud de esta, debido a que la molécula de clorofila está compuesta aproximadamente por 50% de nitrógeno. Este estudio pretende analizar la utilidad que presenta la información multiespectral a la hora de estimar nitrógeno para analizar el estado de salud de las plantas.

4. OBJETIVOS

4.1. Objetivo general:

Estimar el contenido de nitrógeno en dosel para un cultivo de caña de azúcar variedad CC 01-1940 a partir de imágenes multiespectrales.

4.2. Objetivos específicos:

- Construir una base de datos a partir de imágenes multiespectrales tomadas desde RPAS para el cálculo de índices espectrales.
- Segmentar la información espectral para el establecimiento de modelos de correlación entre la información y la variable fotoquímica nitrógeno.
- Implementar un modelo estadístico de regresión por mínimos cuadrados parciales para relacionar el contenido de nitrógeno en dosel en caña de azúcar con índices espectrales.

5. REVISIÓN DE LITERATURA

5.1. Marco conceptual

Con el fin de comprender y lograr un amplio espectro de visión en el estudio que se pretende realizar, es imperativo conocer y distinguir conceptos clave al proceso de estimación de variables biofísicas y fotoquímicas con base en imágenes multiespectrales.

5.1.1. Caña de azúcar:

Es una planta tropical que hace parte de las gramíneas, pertenece a la familia Poaceae y al género *Saccharum*, dentro este existe seis especies, dos silvestres y cuatro cultivadas. Las especies silvestres son *S. mbustum* y *S. spontaneum*, las especies cultivadas son *S. sinense*, *S. barben*, *S. edule* y *S. Officinarum* (Buenaño, 2009).

Saccharum officinarum es una planta de hojas anchas y ásperas, tallo leñoso y flores en panoja, constituida por jugo y fibra, siendo la fibra la parte insoluble en agua y a su vez formada por celulosa. De la caña se extraen diferentes productos entre ellos azúcar, bioetanol y energía generada del jugo de caña por fermentación directa o destilación de melaza fermentada; Obteniendo así un subproducto rico en potasio y materia orgánica llamado vinaza, al igual que la cachaza rica en calcio, fósforo y nitrógeno siendo reincorporadas al suelo por medio de compost, cerrando el ciclo de producción. (Bohórquez et al., 2014)



Figura 2 Cultivo de caña de azúcar **Fuente:** (Cenicaña, 2020)

5.1.2. Etapas fenológicas:

La caña de azúcar tiene un ciclo vegetativo que se divide en 4 etapas de crecimiento definidas, establecimiento es el nombre que recibe la primera etapa esta se subdivide en germinación y emergencia, la segunda fase es la de ahijamiento, la tercera denominada crecimiento rápido y por último la fase de cosecha o maduración (Aguilar, 2011). En la figura 3, se observa una breve descripción de las etapas fenológicas en el cultivo de caña de azúcar.




Figura 3 Etapas fenológicas en el cultivo de caña de azúcar **Fuente:** (Aguilar, 2011)

5.1.3. Nitrógeno:

El nitrógeno, es el séptimo elemento de la tabla periódica identificado con el símbolo N y masa atómica de 14.0067 g/mol, se encuentra en la atmósfera en forma de gas diatómico, ocupando un 78% del aire; aun así en esta forma no es posible su uso por parte de las plantas, requiriendo de una intervención de algunas especies de bacterias, que por medio de procesos de mineralización permiten incorporar el nitrógeno a las plantas (Celaya & Castellanos, 2011). El nitrógeno al interior de la planta se ubica como el nutriente más limitante en la productividad de un cultivo después del agua, ya que cumple dos tipos de funciones: La primera estructural donde se involucra en la síntesis de moléculas esenciales para el crecimiento de la planta, entre ellas encontramos ácidos nucleicos, aminoácidos, proteínas, clorofilas y alcaloides. La segunda es la función como agente osmótico que permite retener el agua en las vacuolas (Cárdenas et al., 2004).

5.1.4. Espectro electromagnético:

Se puede considerar el espectro electromagnético como un campo de energía formado por ondas electromagnéticas organizadas según sus frecuencias o longitudes de onda (Rincón, 2013). En la figura 4, se puede observar la escala del espectro electromagnético.




Figura 4 Espectro electromagnético **Fuente:** (Serway & Jewett, 2018)

5.1.5. Espectroscopia óptica:

Son técnicas experimentales que brindan información de manera indirecta de las propiedades de los materiales, a partir de relaciones entre la estructura de la materia y su interacción con la luz (Purón et al., 2010).

La espectroscopia óptica tiene ventajas frente a las metodologías tradicionales de laboratorio, por la precisión de sus determinaciones, lo que permite reemplazar el uso de reactivos costosos y nocivos para la preparación y procesamiento de muestras en laboratorio (Escobar, 2015).

5.1.6. Índice de vegetación:

Se define como un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda y que pretende extraer información relacionada con la vegetación (Gilabert et al., 1997).

5.1.6.1. Índice de hoja verde (GLI):

Este índice es sensible al cambio en el contenido de clorofila en la hoja, se utiliza para detectar cambios en la clorofila de cultivos y follaje, funciona eficientemente en vegetación viva (Bajinath et al., 2023).

5.1.6.2. Índice de vegetación ajustado al suelo optimizado (GOSAVI):

Es una modificación del NDVI que tiene en cuenta pequeños cambios en el apartado de asimilación de la planta, se utiliza en una etapa temprana del cultivo cuando este no se encuentra cubierto por vegetación exuberante (Szeląg et al., 2023).

5.1.6.3. Índice de vegetación de diferencia normalizada (NDVI):

Es un índice de gran aplicación para determinar la vegetación, ya que es eficiente para el análisis y monitoreo de las condiciones vegetativas y su dinámica en la cobertura terrestre. El NDVI es un índice que es derivado a través de la respuesta de la vegetación en relación con el espectro electromagnético (Olivares & López, 2019).

5.1.6.4. Índice de vegetación de diferencia normalizada verde (GNDVI):

Ampliamente utilizado para estimar tasas fotosintéticas, determinar absorción de agua y nitrógeno de las plantas (Szeląg et al., 2023). también es útil para distinguir plantas estresadas y senescentes, es sensible al contenido de clorofila-a (Lee et al., 2023).

5.1.6.5. Índice de vegetación de diferencia renormalizada (RDVI):

Representa el ajuste de reflectancia de la banda NIR y la banda roja según la salud de la planta. Esto debido a que la planta refleja más NIR cuando está saludable y menos NIR cuando está estresada o muerta (Puerto, 2020).

5.1.6.6. Índice de vegetación mejorado (EVI):

Este índice no se ve afectado por la interferencia atmosférica, tiene una fuerte aplicabilidad a áreas con vegetación de alta densidad y cobertura de nubes (Wang et al., 2023).

5.1.6.7. Índice de vegetación óptimo (VI_{OPT}):

Este índice predice eficientemente el contenido de nitrógeno en cereales (Reyniers et al., 2006).

5.1.6.8. Índice normalizado diferencial de borde rojo (NDRE):

Se basa en el borde rojo y es utilizado comúnmente como indicador de contenido de N en las plantas, estima características bioquímicas con mejor eficiencia que el NDVI (Hassani et al., 2023). Este índice permite calcular de manera más acertada la concentración de clorofila que posee la planta (Bastidas & Naranjo, 2022).

5.1.6.9. Índice de vegetación de diferencia normalizada azul (BNDVI):

Es un índice sin disponibilidad de canal rojo que utiliza el azul visible, para áreas sensibles al contenido de clorofila, amplio uso en cultivos de alfalfa y arroz; relacionado con el índice de área foliar (Hancock & Dougherty, 2007).

5.1.6.10. Índice de coloración o índice de clorofila (CI):

El índice de clorofila (CI) se usa para calcular la cantidad total de clorofila en las plantas (Cenicaña, 2012).

5.1.6.11. Índice de clorofila verde (CIGreen):

Estima el contenido de clorofila en las hojas de las plantas, haciendo uso de la relación de la reflectividad en las bandas NIR y verde (Ahamed et al., 2011).

5.1.6.12. Índice de vegetación de clorofila (CVI):

Se utiliza desde el inicio hasta la mitad del ciclo de crecimiento de un cultivo, útil en una amplia gama de suelos y condiciones de siembra (Vincini & Frazzi, 2011).

5.1.6.13. Índice de clorofila Rojo cercano (Clrededge):

Es un indicador relativamente preciso de la salud en la plantas y puede utilizarse para calcular la cantidad total de clorofila en estas, suele funcionar eficazmente para la gestión de nutrientes (Hunt et al., 2011).

Este índice se correlaciona con la actividad fotosintética de las plantas, se usa para estimar contenido de clorofila el cual a su vez se relaciona con los niveles de nitrógeno disponible en la vegetación (Huarquilla, 2022).

5.1.6.14. Índice de vegetación de diferenciar normalizada mejorada (ENDVI):

Este índice incorpora tres bandas espectrales con el objetivo de producir una mejor discriminación dentro del índice en comparación con el NDVI, ha sido utilizado para el monitoreo agrícola sobre todo en pastizales (Strong et al., 2017).

5.1.6.15. Índice de exceso de verde (ExG):

Este ha sido empleado para segmentar áreas de vegetación verde con el objetivo de identificar y diferenciar entre cultivos y arvenses jóvenes (Woebbecke et al., 1995).

5.1.6.16. Índice de diferencia normalizada verde – rojo (NGRDI):

Comúnmente empleado para estimar biomasa en cultivo, es preciso para separar la vegetación de una amplia gama de suelos o fondos (Bassine, 2019).

5.1.6.17. Índice de diferencia normaliza (NDI):

Este índice es usado para el monitoreo de vegetación y también para identificar cuerpos de agua, existen estudios que indican que es útil para detectar áreas degradadas (Zhang et al., 2020).

5.1.6.18. Índice de contenido de clorofila del dosel (CCCI):

Diseñado para detectar el nitrógeno en dosel utilizando tres bandas de ondas a lo largo del “borde rojo” del espectro (Fitzgerald et al., 2010).

5.1.6.19. Índice de resistencia atmosféricamente visible (VARI):

Está diseñado para resaltar la vegetación en la parte visible del espectro, a la vez que mitiga las diferencias en la iluminación y los efectos atmosféricos (Gitelson et al., 2002).

5.1.6.20. Índice de vegetación transformado (TVI):

Creado a partir de una transformación del NDVI que evita trabajar con valores negativos (Bannari et al., 1995).

5.1.6.21. Índice de vegetación ajustada de suelos modificado (MSAVI):

Reduce los efectos del suelo en la señal de la vegetación (Goel & Qin, 1994).

5.1.6.22. Índice verde triangular (TGI):

Estima el contenido de clorofila y nitrógeno en hojas y copa, basándose en la información de las bandas roja, verde y azul (Hunt Jr. et al., 2011).

5.1.6.23. Índice de diferencia normalizada borde rojo – verde (GNDRE):

Se basa en el borde rojo y es utilizado comúnmente como indicador de contenido de N en las plantas (Messina et al., 2023).

5.1.7. Teledetección:

Esta ciencia permite obtener información espacial, temporal y espectral de un cuerpo u objeto sin entrar en contacto físico con este, todo esto se logra a través de múltiples herramientas como lo son sensores, cámaras de video y espectrofotómetros de campo (Murillo & Carbonell, 2012).

Específicamente en la agricultura, facilita la evaluación de las etapas de crecimiento del cultivo, analiza el estado de salud o vigor vegetal, estudio de necesidades nutricionales, estimación de biomasa, variación espacial de productividad y rendimiento, además de muestreo de variables fotoquímicas como nitrógeno vegetal y clorofila (Aguilar, 2015).

5.1.8. Matriz de co-ocurrencia de nivel de gris (GLCM):

La matriz de co-ocurrencia describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro del área de una ventana determinada. La matriz de coocurrencia es un resumen de la forma en que los valores de los píxeles ocurren al lado de otro valor en una pequeña ventana.

Normalmente el procedimiento de generación de imágenes de textura requiere que el analista defina cinco variables:

1. Tamaño de la ventana.
2. Banda espectral de entrada.
3. Las texturas derivadas.
4. Cuantización (número de bits) del canal de salida.

5. La componente espacial (la distancia Inter píxel y el ángulo para el cómputo de la co-ocurrencia).

Respecto del tamaño de la ventana, esta debe ser cuadrada y con número impar de píxeles. El resultado del cálculo de la textura es un único número que representa la ventana completa, el cual es colocado en el lugar del píxel central. Luego, la ventana se mueve un píxel y el cálculo se repite calculando una nueva matriz de co-ocurrencia para esta nueva ventana y resultando un nuevo valor, para el píxel central de esta nueva posición de la ventana. De este modo se construye toda una nueva imagen con valores de texturas (Presutti, 2004).

5.1.9. Descriptores de texturas de la matriz de co-ocurrencia:

La creación de una matriz normalizada expresada como probabilidad para una determinada relación espacial entre dos píxeles vecinos de la cual pueden derivarse diferentes medidas descriptoras de texturas las cuáles serán los conformadores del vector de características de co-ocurrencia.

5.1.9.1. Variante de textura – Promedio:

Es el valor medio del nivel de gris calculado a partir del histograma de la imagen (Pérez, 2022).

5.1.9.2. Variante de textura – Varianza:

Variabilidad de la respuesta espectral de los píxeles (Tovar, 2019).

5.1.9.3. Variante de textura – Homogeneidad:

También es conocido como momento diferencial inverso, cuando aumenta la homogeneidad indica que el contraste entre las parejas de píxeles desciende (Pérez, 2022).

5.1.9.4. Variante de textura – Contraste:

Es la cantidad de variaciones locales en los tonos de gris de la imagen. El contraste es mayor, si la variación de los tonos también es mayor (Pérez, 2022).

5.1.9.5. Variante de textura – Disimilitud:

Mide la variación local de la imagen (Tovar, 2019).

5.1.9.6. Variante de textura – Entropía:

Es una medida de la complejidad de la imagen, cuanto mayor es la complejidad, mayor será la entropía (Pérez, 2022).

5.1.9.7. Variante de textura – Segundo momento:

También se denomina segundo momento angular o uniformidad. Cuando el segundo momento es mayor, entonces la uniformidad es mayor, es quiere decir que hay un menor variación en los niveles de grises, si el segundo momento es igual a 1, la imagen es completamente uniforme (Pérez, 2022).

5.1.9.8. Variante de textura – Correlación:

Es la dependencia lineal de los tonos de gris en la imagen, es decir, si la correlación es igual a 0, no existe correlación lineal entre los niveles de gris (Pérez, 2022).

5.1.10. Ground Sampling Distance (GSD):

Esta metodología permite a partir de una imagen, medir el tamaño de un objeto así como una segmentación más precisa de la imagen (Lee & Sull, 2019).

5.1.11. Real Time Kinematic (RTK):

Es un sistema de posicionamiento en tiempo real con los que se puede obtener altos niveles de precisión (Takasu & Yasuda, 2009; Mekik & Arslanoglu, 2009).

5.1.12. Correlación de Spearman:

Es una medida de la correlación entre dos variables aleatorias, que es usualmente usado como alternativa cuando las variables estudiadas son ordinales y/o incumplen el supuesto de normalidad (Abad, 2023; Arrogante, 2017; Mendivelso, 2021)

5.1.13. Regresión por mínimos cuadrados parciales (PLS):

La regresión PLS (Partial Least Squares) es un método estadístico multivariante recientemente generalizado. Combina y generaliza conceptos de análisis de componentes principales y de análisis de regresión lineal múltiple resulta particularmente útil cuando se desea predecir un conjunto de variables dependientes (Y) desde un conjunto (relativamente grande y posiblemente correlacionadas) de variables predictoras (X). También resuelve con propiedad el problema de multicolinealidad, que generalmente se supera eliminando las

variables que la causan o transformándolas, solución aplicable si la permanencia del set de variables X no es requerida, es decir cuando necesidades de explicación y predicción no inhiban tal procedimiento. Es apto así mismo cuando el problema requiere considerar relaciones múltiples y cruzadas, y que todas ellas se den simultáneamente o cuando existen variables que no se puedan medir directamente (no observables) no obstante deben ser necesarias para desarrollar la teoría (Legato & Alonso, 2013).

5.1.14. Desviación residual predictiva (RPD):

Mide que tan bien se ajusta el modelo a los datos observados, ya que tiene en cuenta tanto el error de predicción como la variación de los valores. Cuanto mayor es el RPD, mejor será la capacidad predictiva del modelo (Franco & Arjona, 2021).

5.1.15. Importancia de la variable en la proyección (VIP):

La importancia de la variable en la proyección (VIP) representa la contribución de cada predictor al modelo, acumulada por el número de factores del modelo (IBM, 2024).

5.2. Marco de antecedentes

De acuerdo al estado del arte consultado se ha logrado evidenciar avances en la estimación de nitrógeno a partir de la información espectral, dado que una de las metas al desarrollar este trabajo es probar la eficiencia a la hora de estimar este nutriente utilizando imágenes multiespectrales, combinado con modelos estadísticos de regresión no lineal como el PLS, ya que este último ha mostrado buenos resultados a la hora de trabajar con datos hiperespectrales, por lo anterior se pretende explorar el potencial de la información multiespectral haciendo uso de modelos estadísticos robustos lo cual podría resultar en un modelo funcional para estimar el nitrógeno con precisión.

A continuación, se presenta la tabla 1, donde se describen diferentes autores y los resultados obtenidos en sus investigaciones.

Tabla 1 Antecedentes relacionados con espectroscopía, nitrógeno y caña de azúcar **Fuente:** Autores.

Autor/ año	Cultivo y lugar	Objetivos	Resultados de interés	Métricas y modelos
(Zheng et al., 2018)	Oryza sativa (arroz) Rugao, Provincia, Jiangsu, China. Universidad de Nanjing.	Estimar la concentración de nitrógeno vegetal en el arroz, combinando imágenes espectrales basadas en UAV y datos hiperespectrales basados en tierra	Las imágenes multiespectrales basadas en UAV son útiles para estimar la concentración de nitrógeno en arroz, por otra parte, los datos hiperespectrales solo sirven para etapas previas al descabezado del arroz.	Se obtuvieron los resultados en etapa de pre-encabezamiento $R^2 = 0.52 - 0.70$ y en crecimiento $R^2 = 0.39 - 0.68$ y $RMSE = 10.92 - 13.00$ usando regresión lineal simple y regresión lineal multiple por pasos.
(Hurtado & Perafán, 2019)	Saccharum Officinarum. (Caña de azúcar) Valle del cauca, Colombia. Universidad del Valle.	Estimar el contenido de nitrógeno foliar en caña de azúcar con base en la respuesta espectral, usando microsensores adaptados a plataformas aéreas.	Concluye que estimar el contenido durante las diferentes etapas fenológicas y con variaciones de dosis de fertilizante, haciendo uso de este equipo se obtiene de forma precisa a partir de datos de reflectancia difusa en el dosel del cultivo y aplicando método de regresión por mínimos cuadrados parciales.	Se obtuvieron los siguientes resultados $R^2 = 0.977$ y $RMSE = 0.124$ usando PLS.
(Reyes et al., 2021)	Saccharum Officinarum. (Caña de azúcar) Santiago de Cali, Valle del cauca Colombia. Universidad del Valle	Estimar la concentración de nitrógeno en el dosel del cultivo de la caña de azúcar in situ, haciendo uso de la espectroscopia	Se midió la concentración de nitrógeno 60 días a partir de la emergencia de la planta y 60 días después, se obtuvieron datos favorables, confiables y precisos cuando la caña de azúcar está en una etapa temprana de crecimiento, es decir cuando es joven.	Se obtuvieron los siguientes resultados $R^2 = 0.06 - 0.97$ y $RMSE = 3.42 - 19.80$ usando PLS.
(Li et al., 2023)	Triticum aestivum. (Trigo de invierno) Provincia de Henan, Jiaozuo, China. Universidad Politécnica de Henan	Estimar el contenido de nitrógeno en trigo con base en diferencia fraccionada y transformada Wavelet continua a partir de datos hiperespectrales.	Concluye que en la etapa de recogida se presenta una mayor precisión a la hora de estimar nitrógeno, y presenta el modelo wavelet combinado con red neuronal para estimar el contenido de nitrógeno en trigo.	Se obtuvieron los siguientes resultados en promedio $R^2 = 0.71 - 0.76$ y $RMSE = 0.15 - 0.57$ usando SVM, regresión ridge, regresión paso a paso y un red neuronal.
(Hoss et al., 2020)	Zea mays (Maíz).	Asociar el contenido de nitrógeno y el peso seco de la	A alturas de 30, 60, 90 y 120 m de altitud es posible estimar la	Se obtuvieron los siguientes resultados $R^2 =$

	Estado Rio Grande do Sul, Rio dos Indios, Brasil. Universidad Comunitaria de la Región de Chapecó	biomasa aérea del cultivo de maíz con índices de vegetación obtenidos por medio de imágenes multiespectrales aéreas (a diferentes alturas de vuelo), en etapa fenológica V6	biomasa aérea y el contenido de nitrógeno foliar usando NDVI y NDRE, aunque para la altitud de 90 y 120 m se obtuvo los mejores resultados.	0.77 – 0.96 usando ANOVA con prueba la F y análisis de regresión.
(Colorado et al., 2020)	Oryza sativa, (Arroz). Palmira, Valle del Cauca, Colombia. CIAT - Universidad Javeriana.	Estimar nitrógeno en cultivo de arroz con base en imágenes capturadas por UAV	A partir de índices de vegetación calculados de imágenes multiespectrales lograron una mejoría en el modelo de estimación N-to-SPAD a partir de regresiones lineales multivariable y redes neuronales logrando correlaciones superiores al 89%.	Se obtuvieron los siguientes resultados $R^2 = 0.46 - 0.97$ con RMSE 1.687 – 4.356
(Zhang et al., 2023)	Oryza sativa, (Arroz). Provincia de Jiangsu, China.	Diagnosticar el estado nutricional de cultivos de arroz, para dar recomendaciones de fertilización nitrogenada.	El índice RDVI presenta un buen desempeño en el monitoreo de concentración de nitrógeno crítico con bajo rendimiento en determinar la concentración de nitrógeno en plantas y hojas, por su parte el TVI presenta un comportamiento opuesto al anteriormente descrito, dichos resultados fueron obtenidos a partir de una regresión múltiple con variables altamente intercorrelacionadas (red neuronal ELM)	Se obtuvieron los siguientes resultados $R^2 = 0.51 - 0.70$ y RMSE = 0.07 – 1.76 usando SMLR (Step Multiple Linear Regression) además de ELM.
(Akbarian et al., 2022)	Saccharum Officinarum. (Caña de azúcar) Bundaberg, Queensland, Australia.	Mejorar la predicción temprana del rendimiento de la caña de azúcar a nivel de hilera mediante el uso de índices espectrales obtenidos a partir de imágenes multiespectrales de vehículos aéreos no tripulados (UAV).	Se encontró buen rendimiento de los índices NDRE y GRNDVI para la etapa de 6 meses antes de la cosecha.	Se obtuvieron los siguientes resultados $R^2 = 0.67 - 0.74$ y RMSE = 11.77 – 13.22 usando correlación de Pearson y validación cruzada.

5.3. Marco Teórico

A continuación, se presentan las ecuaciones que se utilizarán en el trabajo de grado, de modo que sea comprensible el desarrollo de este.

5.3.1. Contenido de nitrógeno en el dosel:

$$Nc = Nf \times IAF \quad [1]$$

Ecuación 1 Contenido de nitrógeno en el dosel **Fuente:** (Reyes et al., 2021)

Donde: Nc es el contenido de nitrógeno en dosel de la planta, Nf es la concentración de nitrógeno foliar por unidad de área y IAF es el índice de área foliar.

5.3.2. Índice de textura de diferencia normalizada (NDTI):

$$NDTI = \frac{(T_1 - T_2)}{(T_1 + T_2)} \quad [2]$$

Ecuación 2 Índice de textura **Fuente:** (Zheng et al., 2018)

Donde: T_1 y T_2 son medidas aleatorias de textura calculadas a partir de cualquiera de las bandas.

5.3.3. Ecuaciones de textura:

Donde $P_{i,j}$ significa la probabilidad de co-ocurrencia de los valores de gris i y j , para una distancia dada. A continuación se presentan las ecuaciones de cada textura.

$$\text{Contraste} = \sum_{ij=0}^{M-1} P_{ij}(i - j)^2 \quad [3]$$

Ecuación 3 Descriptor de textura - Contraste **Fuente:** (Pérez, 2022)

$$\text{Correlación} = \sum_{ij=0}^{M-1} P_{ij} \left[\frac{(i - \mu_i)(i - \mu_j)}{(\sigma_i^2)(\sigma_j^2)} \right] \quad [4]$$

Ecuación 4 Descriptor de textura - Correlación **Fuente:** (Pérez, 2022)

$$\text{Disimilitud} = \sum_{ij=0}^{M-1} P_{ij}|i - j| \quad [5]$$

Ecuación 5 Descriptor de textura - Disimilitud **Fuente:** (Tovar, 2019)

$$\text{Homogeneidad} = \sum_{ij=0}^{M-1} \frac{P_{ij}}{1 + (i - j)^2} \quad [6]$$

Ecuación 6 Descriptor de textura - Homogeneidad **Fuente:** (Pérez, 2022)

$$\text{Media} = \mu_i = \sum_{ij=0}^{M-1} i(P_{ij}) \quad [7]$$

Ecuación 7 Descriptor de textura – Media (a) **Fuente:** (Pérez, 2022)

$$\text{Media} = \mu_j = \sum_{ij=0}^{M-1} j(P_{ij}) \quad [8]$$

Ecuación 8 Descriptor de textura – Media (b) **Fuente:** (Pérez, 2022)

$$\text{Segundo momento} = \sum_{ij=0}^{M-1} P_{ij}^2 \quad [9]$$

Ecuación 9 Descriptor de textura – Segundo momento **Fuente:** (Pérez, 2022)

$$\text{Varianza} = \sigma_i^2 = \sum_{ij=0}^{M-1} P_{ij}(i - \mu_i)^2 \quad [10]$$

Ecuación 10 Descriptor de textura – Varianza (a) **Fuente:** (Tovar, 2019)

$$\text{Varianza} = \sigma_j^2 = \sum_{ij=0}^{M-1} P_{ij}(j - \mu_j)^2 \quad [11]$$

Ecuación 11 Descriptor de textura – Varianza (b) **Fuente:** (Tovar, 2019)

$$\text{Entropía} = \sum_{ij=0}^{M-1} P_{ij}(-\ln P_{ij}) \quad [12]$$

Ecuación 12 Descriptor de textura - Entropía **Fuente:** (Pérez, 2022)

5.3.4. Error medio cuadrático y error medio cuadrático relativo:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad [13]$$

Ecuación 13 Error medio cuadrático **Fuente:** (Zheng et al., 2018)

$$RMSEr = \frac{100}{\tilde{O}_i} \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad [14]$$

Ecuación 14 Error medio cuadrático relativo **Fuente:** (Zheng et al., 2018)

Donde $\tilde{O}_i$, P_i y O_i fueron los valores observados, predichos y medios de PNC respectivamente, y n fue el número de muestras.

5.3.5. Correlación de Spearman (RHO):

$$Rho \text{ o } \rho = \frac{\sum D^2}{N(N^2 - 1)} \quad [15]$$

Ecuación 15 Ecuación de correlación de Spearman **Fuente:** (Arrogante, 2017)

Donde D es la diferencia entre los rangos x menos y; N es el número de datos.

5.3.6. Regresión de mínimos cuadrados parciales (PLS):

$$Y = X * B + \varepsilon \quad [16]$$

Ecuación 16 Ecuación para mínimos cuadrados parciales **Fuente:** (Reyes et al., 2020)

Donde X corresponden a las variables independientes o predictoras, Y las variables dependientes, B es la matriz de coeficientes de regresión y por último ε es la matriz de residuales.

A continuación, se presenta la tabla 2. Donde está contenida la información de índices de vegetación a calcular en el proyecto.

Tabla 2 Listado de índices vegetativos **Fuente:** Autores

No	ÍNDICES		ECUACIÓN	λ (nm)	REFERENCIA
1	GLI	HOJA VERDE	$\frac{2(GREEN - RED - BLUE)}{2(GREEN + RED + BLUE)}$	420:480 – 490:570 – 640:760	(Widlowski et al., 2000)
2	GOSAVI	VEGETACIÓN AJUSTADO AL SUELO OPTIMIZADO	$\frac{(NIR - GREEN)}{(NIR + GREEN + 0.16)}$	670 - 800	(Samborski et al., 2024)
3	NDVI	VEGETACIÓN DE DIFERENCIA NORMALIZADA	$\frac{(NIR - RED)}{(NIR + RED)}$	670 – 800	(Tucker et al., 1979)
4	GNDVI	VEGETACIÓN DE DIFERENCIA NORMALIZADA VERDE	$\left(\frac{NIR - GREEN}{NIR + GREEN} \right)$	540:570 – 780:1400	(Buschmann & Nagel, 1993)
5	RDVI	VEGETACIÓN DE DIFERENCIA RENORMALIZA DA	$\frac{NIR - RED}{\sqrt{(NIR + RED)}}$	670 - 800	(Broge & Leblanc, 2001)
6	EVI	VEGETACIÓN MEJORADO	$2,5 \left(\frac{NIR - RED}{(NIR + 6RED - 7,5BLUE) + 1} \right)$	420:480 – 640:760 – 780:1400	(Huete et al., 2002)
7	VI _{OPT}	VEGETACIÓN ÓPTIMO	$\frac{(1 + 0,45)(NIR^2) + 1}{(BLUE + 0,45)}$	670:800	(Reyniers et al., 2006)
8	NDRE	INDIDE NORMALIZAD O DIFERENCIAL DE BORDE ROJO	$\frac{NIR - REDEGE}{NIR + REDEGE}$	690:730 – 780:1400	(Clarke et al., 2001)
9	BNDVI	DIFERENCIA NORMALIZADA AZUL	$\frac{NIR - BLUE}{NIR + BLUE}$	420:480 - 780:1400	(Hancock & Dougherty, 2007)
10	CI	ÍNDICE DE COLORACIÓN	$\frac{RED - BLUE}{RED}$	420:480 - 640:760	(Bannari et al., 2016)
11	CI _{Green}	CLOROFILA VERDE	$\frac{NIR}{GREEN} - 1$	490:570- 780:1400	(Ahamed et al., 2011)
12	CVI	CLOROFILA EN VEGETACIÓN	$NIR * \frac{RED}{GREEN^2}$	490:570- 640:760- 780:1400	(Vincini & Frazzi, 2011)
13	Clrededge	CLOROFILA BORDE ROJO	$\frac{NIR}{REDEGE} - 1$	690:730- 780:1400	(Hunt et al., 2011)

14	ENDVI	VEGETACIÓN DE DIFERENCIA NORMALIZADA MEJORADA	$\frac{((NIR + GREEN) - (2 * BLUE))}{((NIR + GREEN) + (2 * BLUE))}$	420:480 - 490:570 - 780:1400	(Strong et al., 2017)
15	ExG	EXCESO VERDE	$\frac{((2 * GREEN) - (RED + BLUE))}{(RED + GREEN + BLUE)}$	420:480 - 490:570 - 640:760	(Baresel et al., 2017)
16	NGRDI	DIFERENCIA NORMALIZADA VERDE/ROJO	$\frac{GREEN - RED}{GREEN + RED}$	490:570 - 640:760	(Bassine et al., 2019)
17	NDI	DIFERENCIA NORMALIZADA	$\frac{RED - GREEN}{GREEN + RED + 0.01}$	490:570 - 640:760	(Zhang et al., 2020)
18	TGI	INDICE TRIANGULAR VERDE	$GREEN - (0.39 * RED) - (0.61 * BLUE)$	420:480 - 490:570 - 640:760	(Hunt et al., 2011)
19	GNDRE	DIFERENCIA NORMALIZADA BORDE ROJO - VERDE	$\frac{REDEGE - GREEN}{REDEGE + GREEN}$	490:570 - 690:730	(Astaoui et al., 2021)
20	MSAVI	VEGETACIÓN AJUSTADA AL SUELO MODIFICADO	$\frac{2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - RED)}}{2}$	640:760 - 780:1400	(Goel & Qin, 1994)
21	TVI	ÍNDICE DE VEGETACIÓN TRANSFORMADA	$\sqrt{(NDVI) + 0.5}$	490:570 - 640:760	(Bannari et al., 1995)
22	VARI	RESISTENCIA ATMOSFÉRICA	$\frac{(GREEN - RED)}{(GREEN + RED - BLUE)}$	459:490 - 545:565 - 620:680	(Gitelson et al., 2002)
23	CCCI	CONTENIDO DE CLOROFILA EN EL DOSEL	$\frac{\frac{NIR - REDEGE}{NIR + REDEGE}}{\frac{NIR - RED}{NIR + RED}}$	690:730 - 780:1400	(Fitzgerald et al., 2010)

Red: Longitud de banda del espectro electromagnético correspondiente al espectro visible (668 nm)

Green: Longitud de banda del espectro electromagnético correspondiente al espectro visible (560 nm)

Blue: Longitud de banda del espectro electromagnético correspondiente al espectro visible (475 nm)

Red Edge: Sección del espectro electromagnético en la que transiciona el rojo y el NIR (717 nm)

NIR: Longitud de banda del espectro electromagnético correspondiente al infrarrojo cercano (840 nm) (MicaSense, 2022).

6. METODOLOGÍA

6.1. Ruta metodológica del proyecto.

A continuación se presenta la metodología realizada para desarrollar a cabalidad todo el proyecto. Destacando los pasos para el procesamiento de las imágenes multiespectrales, para la construcción de los modelos de correlación de Spearman y PLS.




Figura 5 Ruta metodológica **Fuente:** Autores

6.2. Antecedente.

Este trabajo de grado se realizó a partir de los datos tomados en la investigación “BIOINDICADORES ESPECTRALES PARA MONITOREO DEL CULTIVO DE CAÑA DE AZÚCAR EN CONDICIONES DE TENSIÓN AMBIENTAL POR DISPONIBILIDAD DE NITRÓGENO” (Reyes et al., 2020).

El montaje experimental se llevó a cabo entre abril del 2018 hasta agosto del 2019, en la Estación Experimental que hace parte del Laboratorio de Aguas y Suelos Agrícolas, que a su vez es parte de la sede Meléndez de la Universidad del Valle ubicada en la ciudad de Santiago de Cali (3°22'22.58" N; 76°31'47.57" O) ver figura 6., altitud de 995 msnm, clima de bosque seco tropical, ligado a 4 periodos alternados durante el año, 2 de baja precipitación y 2 de alta (Reyes et al., 2021). En la tabla 3. Se realiza la descripción de las características edáficas del experimento.

Tabla 3 Características edáficas de la estación experimental **Fuente:** Adaptado de (Reyes et al., 2021)

Condiciones edáficas	
Tipo de suelos	Udertic Haplustoll
Consociación	Arroyo
Drenaje	Interno lento
	Externo muy lento
Profundidad radicular efectiva	Moderadamente profunda a profunda




Figura 6 Localización de la zona de estudio **Fuente:** (Reyes et al., 2021)

El diseño experimental, se evaluó en los ciclos de plantilla y soca, con 5 repeticiones y 4 tratamientos de fertilización nitrogenada (T1: 0 Kg/ha, T2: 80 Kg/ha, T3: 160 Kg/ha y T4: 240 Kg/ha) como se presenta en la tabla 4., el cultivo seleccionado es caña de azúcar variedad CC 01-1940.

Tabla 4 Características del montaje experimental **Fuente:** (Galíndez, 2022)

ITEM	Valor
Tratamientos	4
Bloques	5
Unidades experimentales (UE)	20
Número de surcos por UE	4
Distancia entre surcos	1,65 m
Distancia de borde ancho	1,65 m
Distancia de borde largo	1 m
Ancho de UE	6,6 m
Largo UE	5 m

En la figura 7. Se puede observar la distribución de bloques completos al azar por efecto de la variabilidad espacial del contenido de materia orgánica, utilizado en el diseño experimental.




Figura 7 Distribución experimental **Fuente:** (Reyes et al., 2020)

6.3. Plan de vuelo.

Para la toma de información multiespectral se realizaron vuelos de RPAS equipado con una cámara MicaSense RedEdge, con la finalidad de abarcar la zona de estudio fueron necesarias 4 líneas de vuelo a alturas entre 60 y 80 metros, en las cuales se obtuvieron imágenes con un GSD (Ground Sampling Distance) de 5 y 50 cm respectivamente; en cuanto a los puntos de control, se levantaron mediante RTK (Real Time Kinematic) tomando puntos de referencia para las parcelas, número de surcos y límites de cultivo como se evidencia en la figura 8 y 9.

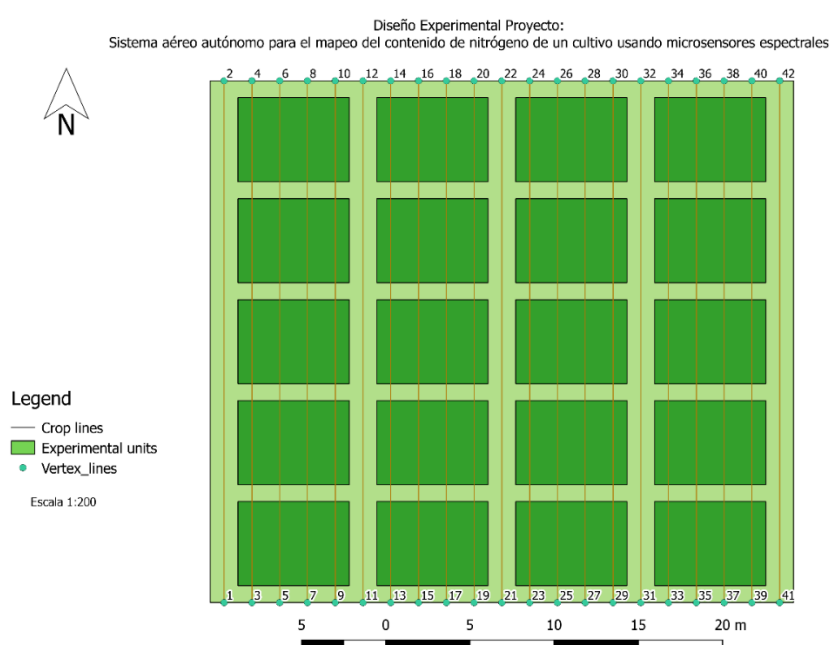


Figura 8 Líneas de cultivo del diseño experimental **Fuente:** (Reyes et al., 2021)




Figura 9 Levantamiento RTK en el diseño experimental **Fuente:** (Reyes et al., 2021)

6.4. Materiales y métodos:

6.4.1. Sistema:

El dispositivo utilizado para tomar las imágenes multispectrales corresponde a la cámara MicaSense RedEdge la cual puede captar 5 bandas del espectro, Blue (475 nm), Green (560 nm), Red (668 nm), Red Edge (717 nm) e infrarrojo cercano (NIR 840nm) con un ancho de banda FWHM de 20, 20, 10, 40 y 10 nm respectivamente (MicaSense, 2022).

Los datos fueron procesados en el software Agisoft Metashape (versión 2.1.3.) dado que este permite utilizar imágenes fijas de objetos para generar nubes de puntos, modelos 3D y ortofotomapas, además cuenta con la capacidad de exportar datos procesados en una amplia gama de formatos (Barbasiewicz et al., 2018).

Para obtener los índices de textura se extrajeron mediciones descriptoras de estas, basados en la matriz de co-ocurrencia de niveles de gris – GLCM, que se realizó mediante el software ENVI ya que en este se pueden realizar dichas mediciones a partir de criterios de homogeneidad, media, entropía, disimilitud, entre otros (Li et al., 2020).

A la hora de construir el modelo estadístico por regresión de mínimos cuadrados parciales, este se desarrolló con base en los datos obtenidos después de los procesamiento de las imágenes y demás, se usó R ya que es un software estadístico que brinda un lenguaje de programación y un entorno de trabajo libre (Lafaye de Micheaux et al., 2014).

6.5. Metodología objetivo específico 1:

Dado que la cámara MicaSense RedEdge cuenta con un panel de calibración, se garantizó la obtención de valores adecuados de reflectancia al momento del procesamiento de las imágenes en el software Agisoft Metashape, después de este primer proceso se construyeron mosaicos. Éstos se trabajaron en el software QGIS (3.34.8) y ArcGIS Pro (versión 3.3.0), con el fin de extraer sus valores digitales de reflectancia para calcular cada uno de los índices espectrales presentados en la tabla 2.

Igualmente, se generó una matriz de coocurrencia de niveles de gris (GLCM) dado que es el algoritmo más utilizado para analizar la textura de las imágenes RPAS, como lo menciona (Zheng et al., 2018).

6.5.1. Procesamiento de imágenes multiespectrales en Agisoft Metashape

Para el procesamiento de las imágenes multiespectrales se siguió el esquema metodológico propuesto por Agisoft Metashape (2023) en el cual se describen los pasos relacionados al procesamiento de imágenes, entre los cuales se incluyen: Agregado de fotos, selección de paneles de reflectancia, valores de reflectancia (albedo) del panel de calibración para las bandas suministrado por MicaSense, ejecución de la calibración de reflectancia, tratamiento de datos en lo que se incluye el alineamiento de fotos, optimización de cámaras, creación de nube de puntos, creación del DEM, creación del ortomosaico y exportado de resultados.

A continuación se presenta el diagrama de flujo para el procesamiento de las imágenes en Agisoft Metashape (Figura 10):



Figura 10 Diagrama de flujo - procesamiento de las imágenes multispectrales en Agisoft Metashape **Fuente:** Autores

6.5.2. Procesamiento de ortomosaicos en ENVI para la GLCM

Para la creación de la matriz de co-ocurrencia de niveles de grises (GLCM), se siguió la metodología propuesta por Manzo & Arzate (2019), quienes explican que la matriz GLCM requiere una orientación (0° , 90° , 45° , 135°) y una distancia de referencia al píxel vecino. La estructura de la matriz resultante debe considerar todas las posibles combinaciones entre los valores de píxel de referencia y el píxel vecino, el procedimiento para generar la matriz GLCM consiste en iterar sobre cada píxel de la imagen, contabilizar y registrar las diferentes tuplas que se forman mediante el píxel de referencia y el píxel vecino. En cada iteración el píxel vecino se convierte en el píxel de referencia, desplazando el valor de la distancia hacia la orientación definida.

Este procesamiento se realizó en el Software ENVI el cual permite crear filtros de co-ocurrencia con una interfaz que permitió la selección de los siguientes parámetros:

- Orientación (0°)

- Tamaño de ventana móvil o distancia de referencia (3x3)
- Bandas para trabajar (RGB, Borde rojo, NIR)
- Descriptores de textura (Promedio, varianza, homogeneidad, contraste, disimilitud, entropía, segundo momento, correlación)

Se seleccionó una ventana móvil o distancia de referencia pequeña, debido a que existe una correlación importante entre píxeles cercanos (Jiménez, 2008). Se creó una sub-escena (debido a que los bordes de los ortomosaicos poseían píxeles con información nula) y una vez finalizado esto, se descargó el ortomosaico con valores de textura en formato .TIFF

Es necesario mencionar que, se realizó el cálculo de los diferentes descriptores o tipos de textura para cada banda, por lo que los mosaicos extraídos de ENVI poseen un total de 40 bandas, correspondientes a 5 bandas espectrales (rojo, verde, azul, borde rojo y NIR) y a los 8 tipos de textura (ecuación 3 a 12) (Prasert, 2005).

A continuación se presenta el diagrama de flujo para el procesamiento de las imágenes en ENVI (Figura 11):



Figura 11 Diagrama de flujo - procesamiento de los ortomosaicos en ENVI **Fuente:** Autores

6.5.3. Extracción de información espectral:

Una vez se contó con los ortomosaicos para cada campaña con valores de reflectancia (procesamiento en Agisoft MetaShape) y valores de textura (procesamiento en ENVI) se realizó la creación de una capa de geometría de puntos en el software Qgis, los puntos de esta capa representaron cada una de las plantas del cultivo del montaje experimental. Para el ciclo de plantilla (año 2018) se crearon alrededor de 400 puntos por campaña donde se capturó el píxel más puro, y para el ciclo de soca (año 2019) se crearon alrededor de 4000 puntos por campaña, esta diferencia entre el número de puntos se debe a que el cultivo en el ciclo de soca presenta mayor desarrollo de biomasa aérea, lo que permitió seleccionar distintos píxeles conservando información propia de la cepa.

Contando con todos los puntos en las posiciones deseadas se utilizó la herramienta “Muestra de valores de ráster” la cual es una función del software, Qgis que permite extraer el valor puntual (píxel) de la capa ráster sobre la cual se está trabajando, posteriormente al uso de esta herramienta se realizó la exportación de la información contenida en la capa con geometría de puntos, a hojas de cálculo (.xls o .csv) para el cálculo de los índices espectrales. Debido a que no todas las campañas contaban con información referente para su debida geolocalización en la creación de los ortomosaicos en el software Agisoft MetaShape, fue necesario utilizar ArcGIS Pro con la finalidad de georreferenciar cada uno de los mosaicos obtenidos.

6.5.4. Cálculo de los índices espectrales:

El cálculo de los índices espectrales se realizó a partir de la combinación de las bandas presentadas en la tabla 2. Posteriormente se obtuvo el promedio de los resultados obtenidos para cada punto muestreado, es decir, para el caso de la soca, se calcularon los distintos índices espectrales para los 4000 puntos creados y luego se calculó un promedio para la parcela de acuerdo con la posición de estos.

El procedimiento descrito anteriormente se realizó de esa forma dado que el protocolo recomendado por Cenicaña (2025) para la toma de tejido foliar, consiste en la recolección de

tercios de hojas (se elimina la parte inferior y superior, conservando solo la sección media de la hoja) de una muestra significativa del cultivo.

6.6. Metodología objetivo específico 2:

Con la finalidad de correlacionar la información espectral con la variable fotoquímica nitrógeno, se accedió a la información tomada por Reyes et al. (2021), y se extrajeron los datos necesarios para ser analizados (20 datos de nitrógeno en g/m^2).

Una vez la información se categorizó y organizó, haciendo uso del software R se procesó la información espectral calculada anteriormente junto a los resultados de nitrógeno tomados en laboratorio, para mediante el análisis de correlación de Spearman (ecuación 15) examinar la relación entre las variables dependientes e independientes que ingresaran al modelo de PLS. Debido a que varios de los índices espectrales calculados, no tienen una distribución normal o presentan valores extremos se empleó este método para que los resultados no se vean afectados (Martínez et al., 2009).

Es pertinente señalar que otros métodos de correlación como Pearson cuantifican la fuerza y la dirección de las relaciones lineales entre variables continuas. En contraste, Kendall y Spearman permiten evaluar asociaciones monótonas entre dos variables y se destacan por tener mayor robustez frente a la presencia de valores atípicos, aunque Spearman puede tener mayor sensibilidad en muestras pequeñas siendo capaz de identificar correlaciones con mayor facilidad en estas circunstancias (Patanè et al., 2025; Puth et al., 2015).

La evaluación de la correlación entre el contenido de nitrógeno en g/m^2 y los índices espectrales, por medio de Spearman se realizó basándonos en los rangos establecidos por (Barrera, 2014), tal como se muestra en la tabla 5.

Tabla 5 Rangos para la correlación de Spearman. Fuente: (Barrera, 2014)

RANGO	RELACIÓN
-0.91 a -1.00	Correlación negativa perfecta
-0.76 a -0.90	Correlación negativa muy fuerte
-0.51 a 0.75	Correlación negativa considerable
-0.11 a -0.50	Correlación negativa media
-0.01 a -0.10	Correlación negativa débil
0.00	No existe correlación
0.01 a 0.10	Correlación positiva débil
0.11 a 0.50	Correlación positiva media
0.51 a 0.75	Correlación positiva considerable
0.76 a 0.90	Correlación positiva muy fuerte
0.91 a 1.00	Correlación positiva perfecta

6.7. Metodología objetivo específico 3:

Dado que, en comparación con los datos de reflectancia espectral, está demostrado que los índices de vegetación reducen la influencia de la geometría del dosel, el fondo del suelo, los ángulos de iluminación y las condiciones atmosféricas al estimar las propiedades biofísicas, se asumió que el índice de textura con relación o normalización de las medidas de textura presenta la misma función que un índice de textura normalizada ecuación 2 (Zheng et al., 2018).

Los datos estadísticos se combinaron para examinar la relación de nitrógeno (Nc) con los índices de vegetación e índices de textura (NDTI) por medio de una regresión de mínimos cuadrados parciales (ecuación 16), adicionalmente, el rendimiento del modelo de estimación se evaluó a partir de las métricas R^2 y RPD, con base en (Reyes et al., 2021), ver tabla 6.

Tabla 6 Métricas para evaluar el rendimiento del modelo Fuente: (Reyes et al., 2021)

Rendimiento del modelo			
Métricas	Inaceptable	Aceptable	Bueno
R^2	< 0.50	0.50 - 0.75	> 0.75
RPD	< 1.40	1.40 - 2.00	> 2.00

Con el objetivo de evaluar la correlación entre el Nc y los índices espectrales derivados de las imágenes multiespectrales, se compararon los resultados obtenidos frente a los valores

de Nc determinados a través del método Kjeldahl en laboratorio por Reyes et al. (2021) para identificar el modelo más eficiente en estimar Nc de acuerdo al error medio cuadrático asociado (ecuación 13 y 14).

El modelo PLS se validó con el número de componentes óptimos identificados a través de la validación cruzada (Leave-Out-One, "LOO") con el objetivo de no sobreestimar el modelo, el número de componentes óptimos se seleccionó de forma tal que minimice el error y maximice la varianza explicada de los datos, además se realizó un análisis sobre la importancia de las variables en la proyección (VIP) con la finalidad de identificar cada uno de los índices espectrales que más influyen en la estimación del Nc.

La información se segmentó en proporción 80/20 (80% de entrenamiento y 20% para validación) garantizando que en cada conjunto se encuentre al menos una muestra de cada uno de los tratamientos empleados en el montaje experimental.

7. RESULTADOS Y DISCUSIÓN

7.1. Procesamiento de imágenes multiespectrales

Para la construcción de la base de datos que permitió el cálculo de índices espectrales, en primera instancia fue necesario realizar un procesamiento a las imágenes multiespectrales con el propósito inicial de transformar los números digitales para obtener los valores de reflectancia (este procesamiento se realizó en Agisoft Metashape a partir de los datos de albedo que el soporte técnico de MicaSense proporciona de acuerdo al número de referencia del sensor utilizado), en este procesamiento se realizó la construcción de los ortomosaicos en valores de reflectancia, el cálculo de los valores de textura, la extracción de la información digital de cada campaña y por último la construcción de los índices espectrales, como se describe a continuación.

7.1.1. Verificación de imágenes multiespectrales

Dado que las imágenes obtenidas a partir de la cámara MicaSense son separadas por cada una de las bandas del espectro electromagnético que esta logra captar, el primer paso en la verificación de la imágenes es comprobar que cada una de las campañas cuente con un numero de archivos divisibles por cinco, correspondiente a las bandas azul, verde, rojo, borde rojo y NIR. A continuación se presenta la imagen correspondiente al panel de calibración y la banda NIR para el cultivo en el ciclo de soca (Ver figura 12).




Figura 12 (a) Panel de calibración de la cámara (b) Cultivo en ciclo de soca **Fuente:** Autores.

7.1.2. Construcción de ortomosaicos en valores de reflectancia con Agisoft Metashape.

A continuación, se presenta el resultado obtenido del procesamiento de las imágenes multispectrales en Agisoft Metashape (ver figura 13.), en el cual se construyó el ortomosaico donde se obtuvieron los valores de reflectancia de cada una de las campañas realizadas.

Debido a que las fotografías de los paneles de calibración son utilizadas para el ajuste radiométrico del mosaico, el software las excluye automáticamente pues no forman parte de este último.




Figura 13 Procesamiento en Agisoft Metashape campaña en ciclo de plantilla **Fuente:** Autores

En la figura 14 se puede observar el resultado del procesamiento realizado en Agisoft, a partir del cual se obtuvo el ortomosaico corregido radiométricamente, este permitió generar un mapa temático en colores verdaderos ejemplificado por la campaña 4.




Figura 14 Representación color verdadero postprocesamiento en Agisoft **Fuente:** Autores

7.1.3. Georreferenciación de los ortomosaicos

Este proceso se realizó a partir de puntos de control georreferenciados ubicados estratégicamente en el área de estudio, mediante el uso del software ArcGIS así como se puede observar a continuación (Figura 15).




Figura 15 Georreferenciación en ArcGIS **Fuente:** Autores

En la siguiente figura (16) se muestra un acercamiento para presentar la ubicación de los puntos de control (Lonas) dentro del área de estudio, de manera más apropiada.



Figura 16 Zoom a los puntos de control en la campaña **Fuente:** Autores

7.1.4. Estimación de valores de textura con ENVI.

La estimación de valores de textura desde ENVI se hizo a partir del filtro “GLCM (Co-ocurrencia)” ver figura 17, desde el cual se crearon 8 datos de textura diferentes para cada una de las bandas, correspondientes a: Entropía, Segundo Momento, Correlación, Promedio, Varianza, Disimilitud, Contraste y Homogeneidad, con una ventana móvil de 3x3 (número de píxeles), los tipos de textura se pueden observar en la figura 18.




Figura 17 Filtro de textura en ENVI **Fuente:** Autores




Figura 18 Parámetros de textura en ENVI **Fuente:** Autores

Teniendo en cuenta los parámetros mencionados anteriormente fue necesario realizar el procesamiento de las imágenes estableciendo una sub-escena, dado que la ventana móvil cubre toda la extensión de las imágenes y estas presentan valores nulos o inexistentes en sus bordes, haciendo que los cálculos de los valores de textura no sean posibles. Ver figura 19.




Figura 19 Creación de sub-escena **Fuente:** Autores

En la figura 20 se observa el resultado obtenido del procesamiento en ENVI, el cual resulta en un total de 40 bandas, referentes al RGB, Borde rojo y NIR en cada una de las variantes de textura mencionadas anteriormente.

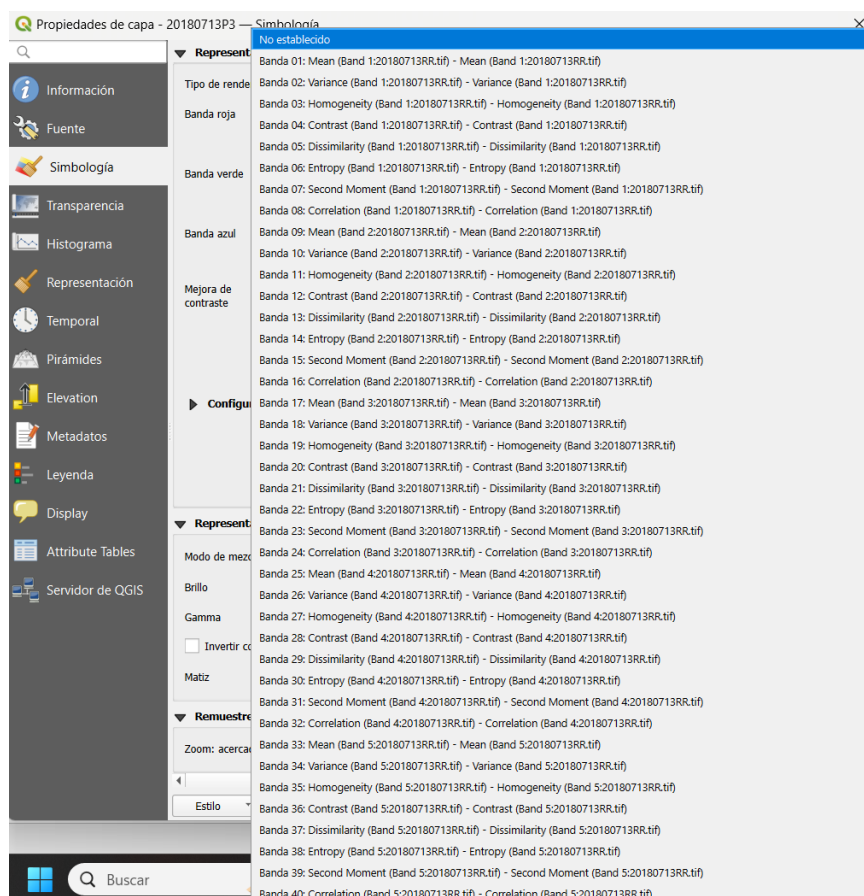


Figura 20 Bandas obtenidas después del procesamiento en ENVI **Fuente:** Autores

7.1.5. Extracción de valores digitales de las campañas y construcción de base de datos

Posterior al ajuste radiométrico y habiendo homogeneizado geométricamente las campañas, se construyeron puntos correspondientes a las cepas de caña con el fin de extraer los valores de reflectancia y textura, para construir la base de datos de índices espectrales. Ver figuras 21 y 22.




Figura 21 Creación de puntos en QGIS para el ciclo de plantilla **Fuente:** Autores




Figura 22 Creación de puntos en QGIS para el ciclo de soca **Fuente:** Autores

Dado el gran número de puntos utilizados en la extracción de valores digitales de los ortomosaicos, se consiguieron diversos valores de reflectancia para las mismas parcelas, por lo que se realizó el cálculo del promedio de cada uno de los índices espectrales correspondientes a cada parcela.

Para las campañas del ciclo de soca, se obtuvieron 4.5 millones de datos y para el ciclo de plantilla 340 mil, lo que derivó en un total de 4515 datos por campaña después de generar el promedio, para su evaluación por medio de Spearman y PLS. Ver figura 23 y 24.




Figura 23 Datos de todas las campañas del año 2019 (ciclo de soca) **Fuente:** Autores




Figura 24 Promedio de los índices por campañas (ciclo de soca) **Fuente:** Autores

7.2. Correlación de Spearman

De acuerdo con las métricas establecidas para la evaluación de la correlación de Spearman, se realizaron “mapas de calor”, los cuales relacionan cada una de las variables con el nitrógeno, esto generó una matriz de 208 x 208 para cada campaña (que no es posible visualizarse de forma correcta – ver anexo 1 y 2), se presenta la relación del nitrógeno frente a cada uno de los índices espectrales con sus respectivas variantes de textura. Ver tabla 7.

Se omitió el resultado de la correlación nitrógeno – nitrógeno debido a que siempre será positiva perfecta ($\rho = 1.0$), sin embargo en la matriz completa se podrá observar (con la estructura tradicional de la correlación de Spearman). Dado que el propósito es evaluar la relación que presentan los índices espectrales en sus diferentes variantes (tradicional y textura) con el nitrógeno, en la tabla 7, se presenta cada uno de los índices utilizados (columna 1), de este modo la interpretación de la tabla se realiza seleccionando una opción tanto en la fila 1 como en la columna 1, dando lugar a una intersección la cual representa el valor de Rho.

Tabla 7 Correlación de Spearman (Nitrógeno vs Índices espectrales) en campaña 1 **Fuente:** Autores

CAMPAÑA 1	VEGETATIVO	PROMEDIO	VARIANZA	HOMOGENEIDAD	CONTRASTE	DISIMILITUD	ENTROPIA	SEGUNDO MOMENTO	CORRELACION
INDICE	NITROGENO								
GLI	0.0	-0.2	0.2	-0.1	0.0	0.0	0.3	-0.2	0.0
GOSAVI	-0.2	0.1	0.3	0.2	-0.1	0.0	-0.1	0.0	0.0
NDVI	0.2	0.1	0.3	0.2	0.1	0.1	0.0	0.0	-0.2
GNDVI	0.1	0.2	0.3	0.3	-0.1	0.0	0.1	0.0	0.0
RDVI	-0.1	-0.1	0.3	0.0	0.0	-0.1	0.4	-0.2	0.1
EVI	-0.1	-0.1	0.2	0.3	-0.2	-0.2	-0.1	0.1	0.1
VIOPT	-0.1	-0.1	0.3	-0.2	0.0	0.0	0.1	0.1	0.0
NDRE	-0.1	-0.1	0.3	0.2	0.2	0.1	0.2	0.0	0.0
BNDVI	0.2	0.1	0.3	0.2	0.1	0.1	0.0	0.0	-0.2
CI	0.1	0.1	0.1	-0.1	0.0	0.2	0.1	0.0	-0.2
CIGreen	0.1	0.2	0.3	0.3	0.0	0.0	-0.1	0.2	0.4
CVI	0.0	0.2	0.0	0.3	0.1	0.0	-0.3	0.3	0.3
Cirededge	-0.1	-0.1	0.3	0.2	0.2	0.1	0.5	-0.1	0.0
ENDVI	0.2	0.1	0.3	0.1	0.2	0.1	0.2	-0.1	-0.1
ExG	0.0	-0.2	0.2	-0.1	0.0	0.0	0.3	-0.2	0.0
NGRDI	-0.1	-0.2	0.2	-0.1	0.0	0.0	0.2	-0.2	-0.3
NDI	0.1	0.2	-0.2	0.1	0.0	-0.1	-0.5	0.3	0.3
TGI	0.0	-0.1	0.1	-0.1	0.0	0.0	0.3	-0.3	0.0
GNDRE	0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.5	0.4	0.3
MSAVI	-0.1	0.0	0.3	0.0	0.0	0.0	0.5	-0.4	0.0
TVI	0.2	0.1	0.3	0.2	0.1	0.1	0.0	-0.1	-0.3
VARI	-0.1	-0.2	0.2	-0.1	0.0	-0.2	0.2	-0.2	-0.2
CCCI	-0.1	-0.1	-0.1	0.0	0.2	0.2	-0.2	-0.1	0.1

En las tablas a continuación (8 y 9) se presentan el tipo de índice espectral, el índice objeto de estudio, las bandas y las correlaciones más fuertes por campaña, considerando tanto ρ negativo y positivo. Cabe aclarar que el tipo “correlación” hace referencia a una de las variantes de textura.

Tabla 8 Resultados significativos en el ciclo de plantilla **Fuente:** Autores

CAMPAÑA	TIPO	INDICE	BANDAS	p
1	ENTROPIA	Clrededge	BORDE ROJO - NIR	0.5
	ENTROPIA	NDI	ROJO - VERDE	-0.5
	ENTROPIA	GNDRE	BORDE ROJO - VERDE	-0.5
	ENTROPIA	MSAVI	ROJO - NIR	0.5
	SEGUNDO MOMENTO	GNDRE	BORDE ROJO - VERDE	0.4
2	CORRELACION	NGRDI	ROJO - VERDE	0.8
	CORRELACION	NDI	ROJO - VERDE	-0.7
	CORRELACION	GLI	ROJO – VERDE - AZUL	0.6
	CORRELACION	ExG	ROJO – VERDE - AZUL	0.6
	CORRELACION	TGI	ROJO – VERDE - AZUL	0.6
3	CORRELACION	MSAVI	ROJO - NIR	0.6
	CORRELACION	VIOPT	AZUL - NIR	0.6
	CORRELACION	TVI	ROJO - NIR	0.6
	CORRELACION	NDVI	ROJO - NIR	0.5
	CORRELACION	BNDVI	AZUL - NIR	0.5
4	PROMEDIO	RDVI	ROJO - NIR	0.7
	PROMEDIO	NGRDI	ROJO - VERDE	0.7
	PROMEDIO	NDI	ROJO - VERDE	-0.7
	PROMEDIO	CI	ROJO - AZUL	-0.7
	PROMEDIO	VARI	ROJO – VERDE - AZUL	0.7

Tabla 9 Resultados significativos en el ciclo de soca **Fuente:** Autores

CAMPAÑA	TIPO	INDICE	BANDAS	p
5	VARIANZA	MSAVI	ROJO - NIR	0.6
	PROMEDIO	GLI	ROJO - VERDE - AZUL	0.6
	PROMEDIO	ExG	ROJO - VERDE - AZUL	0.6
	HOMOGENEIDAD	EVI	ROJO - AZUL - NIR	0.6
	VARIANZA	NGRDI	ROJO - VERDE	0.5
6	VEGETATIVO	CVI	ROJO – VERDE - NIR	-0.5
	VEGETATIVO	TGI	ROJO - VERDE - AZUL	0.4
	VARIANZA	CCCI	ROJO - BORDE ROJO - NIR	-0.4
	VEGETATIVO	CI	ROJO - AZUL	-0.4
	PROMEDIO	EVI	ROJO – AZUL - NIR	0.4
7	VARIANZA	VIOPT	AZUL - NIR	0.6
	CONTRASTE	CCCI	ROJO - BORDE ROJO - NIR	0.6
	CONTRASTE	CIGreen	VERDE - NIR	-0.6
	VARIANZA	CIGreen	VERDE - NIR	-0.6
	ENTROPIA	MSAVI	ROJO - NIR	0.6
8	ENTROPIA	VIOPT	AZUL - NIR	-0.7
	ENTROPIA	GNDRE	BORDE ROJO - VERDE	-0.5
	ENTROPIA	GOSAVI	VERDE - NIR	-0.5
	ENTROPIA	NGRDI	ROJO - VERDE	-0.5
	SEGUNDO MOMENTO	GNDRE	BORDE ROJO - VERDE	0.5

Para la campaña 2, 4, 7 y 8 se encontraron correlaciones considerables con una predominancia de las bandas roja y NIR, las campañas 1 y 6 presentaron una correlación media donde se ve tendencia en índices del espectro visible. Conforme con Rojas (2023) la respuesta multispectral presenta variaciones en la reflectancia de acuerdo con el grado de fertilización nitrogenada, donde la banda del NIR presenta unos niveles más altos y el espectro visible niveles más bajos para el caso de estudio de Rojas (2023) se presentaron valores de p superiores a 0.45 con el contenido de nitratos coincidiendo justamente con índices que corresponden a operaciones entre bandas de las regiones verde, rojo e infrarrojo. Los altos niveles de coeficientes obtenidos a partir de Spearman, comprueba que la estimación de nitrógeno se puede hacer mediante el uso de índices espectrales, tal como lo indica Mesa & Silva (2015) el cual en su estudio encontró que, el contenido diferencial de nitrógeno en las hojas no es detectable por medio de firmas espectrales pero si por medio de índices, esto en el cultivo de papa, donde se encontraron correlaciones significativas p superiores a 0.51.

De acuerdo con los coeficientes de correlación de Spearman se pueden destacar los índices NGRDI, NDI y RDVI por mostrar correlaciones positivas o negativas fuertes, estos índices han sido utilizados en distintos estudios tales como Tafolla (2021), Zheng et al. (2018) y Miphokasap et al. (2012) con la finalidad de medir o determinar contenido de nitrógeno foliar en distintos cultivos, donde obtuvieron resultados $R^2=0.93$; $RMSE=0.04$ en lechuga romana, $R^2=0.740$; $RMSE=0.38$ en trigo de invierno y $R^2=0.78$; $RMSE=0.04$ en caña de azúcar respectivamente.

En el ciclo de plantilla se presenta una correlación promedio superior al ciclo de soca (en los índices con mejores correlaciones), lo que indica una mejor correlación de los índices espectrales con los valores de nitrógeno determinados bajo el método tradicional, por lo que en esta etapa es el mejor momento para la obtención de datos bajo el criterio de esta correlación. Dentro del mismo ciclo de plantilla se logra identificar que los periodos de 89 y 150 días después de la siembra (DDS) se obtienen las mejores correlaciones entre los índices

espectrales y el contenido de nitrógeno en la planta, con una predominancia de la variante de textura “correlación” y “promedio” respectivamente.

7.3. Modelo PLS entre índices espectrales y Nitrógeno.

El modelo PLS se propuso con N_c (g/m²) a partir de datos espectrales transformados a índices de vegetación con variantes de textura. Se evaluaron cuatro campañas por cada ciclo en la etapa fenológica de rápido crecimiento para identificar el momento óptimo de adquisición de datos en campo. El número óptimo de componentes principales se seleccionó minimizando el error cuadrático medio de la validación cruzada y maximizando el coeficiente de determinación, con el fin de evitar el sobreajuste del modelo.

Además de lo mencionado, se consideró el “método del codo” ya que permite analizar de forma simple y visual el número óptimo de componentes, a partir del cual ya no se producen variaciones importantes, tal como lo indica Díaz (2020). A continuación en las figuras 25 y 26 se presenta la relación $RMSE_{normalizado}$ vs número de componentes (obtenidos a partir de los índices espectrales) bajo las cuales se hicieron el análisis de componentes principales para el modelo PLS. Las campañas 1, 2, 3 y 4 corresponden al ciclo de plantilla y 5, 6, 7 y 8 al ciclo de soca.




Figura 25 RMSEnormalizado vs Número de componentes (a) campaña 1 (b) campaña 2 (c) campaña 3 y (d) campaña 4 **Fuente:** Autores




Figura 26 RMSEnormalizado vs Número de componentes (a) campaña 5 (b) campaña 6 (c) campaña 7 y (d) campaña 8 **Fuente:** Autores

A continuación, se presenta las tablas resúmenes de los resultados obtenidos en la validación del modelo PLS por campaña.

Tabla 10 Resultados del modelo en el ciclo de plantilla **Fuente:** Autores

FECHA	DDS	CAMPAÑA	NCO	RMSErVal (%)	R ² Val	RPDVal
13/07/2018	84	1	5	13.395	0.756	2.044
18/07/2018	89	2	2	5.623	0.987	2.905
23/08/2018	125	3	1	8.268	0.772	2.389
17/09/2018	150	4	5	2.431	0.999	3.806

DDS: Días después de la siembra. NCO: Número de componentes óptimo. RMSEr: Error de raíz cuadrada media relativo. RPD: Desviación residual predictiva. R²: Varianza explicada. Val: validación

Tabla 11 Resultados del modelo en el ciclo de soca **Fuente:** Autores

FECHA	DDC	CAMPAÑA	NCO	RMSErVal (%)	R ² Val	RPDVal
15/02/2019	95	5	3	9.51	0.935	2.574
11/03/2019	119	6	8	5.299	0.776	1.879
11/06/2019	211	7	3	8.06	0.735	2.071
12/07/2019	242	8	7	5.675	0.83	1.774

DDC: Días después de la cosecha. NCO: Número de componentes óptimo. RMSEr: Error de raíz cuadrada media relativo. RPD: Desviación residual predictiva. R²: Varianza explicada. Val: validación

Una vez determinado el número óptimo de componentes, se procedió a entrenar el modelo y estimar el parámetro Nc. Los resultados de la regresión PLS para la etapa de plantilla (ver tabla 10) evidenciaron una buena capacidad predictiva, con coeficientes de determinación (R²) superiores a 0.75 y errores cuadráticos medios relativos (RMSEr) inferiores al 14% en la mayoría de las campañas.

El RPD en la validación confirmó el buen rendimiento en la mayoría de los modelos obtenidos, como se puede ver en la tabla resumen de los resultados del modelo (tablas 10 y 11). Estos hallazgos sugieren que los momentos más adecuados para la adquisición de datos en campo son a los 89 y 150 DDS en el ciclo de plantilla y a los 95 DDC en el ciclo de soca, ya que los modelos desarrollados para estas fases presentaron los mejores indicadores de ajuste. Los resultados obtenidos son congruentes con investigaciones previas (Amaral et al., 2015; Portz et al., 2013), las cuales respaldan el uso de sensores de reflectancia del dosel en las primeras etapas de desarrollo de la caña de azúcar, obteniendo resultados de R² iguales o superiores a 0.70 con un RMSE que osciló entre 4.8 – 10.4 %.

En el ciclo de soca, los resultados de las transformaciones espectrales mostraron una coherencia notable con el de plantilla, especialmente a los 95 DDC. En su mayoría las campañas presentaron un RMSEr inferior al 10% y una varianza explicada superior al 73%. De manera particular, la campaña 5 destacó por su buen desempeño, alcanzando un coeficiente de determinación superior al 0.93 y un RPD mayor a 2.0, lo que indica una alta precisión en la estimación de Nc.

La construcción de modelos PLS considerando Nc y reflectancia a escala de dosel, mejora el desempeño de estos debido a la fuerte influencia de la fertilización con N en el desarrollo del componente foliar del dosel (Reyes et al., 2020).

7.4. Coeficientes de regresión del modelo.

A continuación, se presentan los coeficientes de regresión que se obtuvieron por ciclo (plantilla y soca) con el objetivo de visualizar la relación entre las variables tanto independientes como dependientes. Ver figura 27 y 28.




Figura 27 Coeficientes de regresión en etapa de plantilla (a) campaña 1 (b) campaña 2 (c) campaña 3 (d) campaña 4 **Fuente:** Autores




Figura 28 Coeficientes de regresión en etapa de soca (a) campaña 5 (b) campaña 6 (c) campaña 7 (d) campaña 8 **Fuente:** Autores

En las tablas 12 y 13 se presentan los 3 mejores resultados en los coeficientes de regresión por campaña, donde se pueden observar el tipo de índice, el índice objeto de estudio y las bandas del espectro que involucran.

Tabla 12 Coeficientes de regresión significativos en el ciclo de plantilla **Fuente:** Autores

CAMPAÑA	TIPO	ÍNDICE	BANDAS	COEF. DE REG.
1	ENTROPIA	Clrededge	NIR-BORDE ROJO	0.153
	CORRELACION	CI	ROJO-AZUL	-0.127
	ENTROPIA	GNDRE	BORDE ROJO-VERDE	-0.119
2	CORRELACION	GLI	ROJO-VERDE-AZUL	0.092
	CORRELACION	ExG	ROJO-VERDE-AZUL	0.092
	CORRELACION	NDI	ROJO-VERDE	-0.090
3	VARIANZA	EVI	NIR-ROJO-AZUL	-0.069
	DISIMILITUD	EVI	NIR-ROJO-AZUL	-0.064
	HOMOGENEIDAD	CI	ROJO-AZUL	0.055
4	CORRELACION	VARI	ROJO-VERDE-AZUL	0.315
	ENTROPIA	BNDVI	NIR-AZUL	-0.219
	SEGUNDO MOMENTO	EVI	NIR-ROJO-AZUL	0.210

Tabla 13 Coeficientes de regresión significativos en etapa de soca **Fuente:** Autores

CAMPAÑA	TIPO	ÍNDICE	BANDAS	COEF. DE REG.
5	VEGETATIVO	CVI	ROJO-VERDE-NIR	-0.026
	VEGETATIVO	TGI	ROJO - VERDE - AZUL	0.025
	VEGETATIVO	CCCI	ROJO - BORDE ROJO - NIR	-0.022
6	CORRELACION	ENDVI	VERDE-AZUL-NIR	0.152
	CORRELACION	CVI	ROJO-VERDE-NIR	-0.111
	CONTRASTE	MSAVI	ROJO - NIR	0.100
7	VARIANZA	EVI	ROJO - AZUL - NIR	0.272
	VARIANZA	CI	ROJO-AZUL	-0.193
	CONTRASTE	EVI	ROJO - AZUL - NIR	0.190
8	SEGUNDO MOMENTO	VIOPT	AZUL-NIR	-0.518
	HOMOGENEIDAD	VIOPT	AZUL-NIR	-0.479
	ENTROPIA	VIOPT	AZUL-NIR	0.392

La contribución de cada índice espectral al desempeño del modelo PLS, se analizó observando el comportamiento de los coeficientes de regresión, dado que estos representan la importancia que cada variable explicativa tiene en la predicción de las variables respuesta (Márquez, 2017). Se percibió buena actividad en índices contruidos a partir de las regiones del rojo (668 nm y ancho de banda 10 nm), borde rojo (717 nm y ancho de banda 40 nm) e infrarrojo cercano (840 nm y ancho de banda 10 nm).

De acuerdo con investigaciones realizadas por Zhao et al. (2007) y Raddi et al. (2022), la clorofila es un indicador biológico crucial que refleja varios procesos fisiológicos relacionados con la fenología, la eficiencia fotosintética y la detección del estrés en las plantas. En los últimos años, se han propuesto distintos métodos para estimar la cantidad de clorofila, utilizando índices de vegetación simples que permiten medirla en diferentes escalas espectrales, dichos índices estudiados están especialmente ubicados en las regiones del borde rojo e infrarrojo cercano, obteniendo resultados prometedores para dicha labor. Como se mencionó anteriormente la clorofila está fuertemente relacionado con el nitrógeno.

Se pueden destacar algunos índices como el VIOPT, VARI, Clrededge y EVI los cuales son utilizados generalmente para la detección de estados de nitrógeno, concentración de nitrógeno, detección de IAF y predicciones de rendimiento, presentando algunos de los coeficientes de regresión más representativos (Jiménez et al., 2019; Fitzgerald et al., 2010; Huarquilla, 2022). Los indices mencionados se encuentran en la correlación de Spearman

destacados con una correlación considerable, donde la variante de textura entropía sobresale dado que diversos de sus índices hacen aportes considerables a la estimación de nitrógeno (tabla 8 y 9).

7.5. Importancia de la variable en la proyección para el modelo PLS.

Los resultados obtenidos para el VIP se analizaron a partir de la interpretación de la tabla 14 adaptada de (Reyes et al., 2020).

Tabla 14 Interpretación VIP **Fuente:** Autores

Métrica	Interpretación
VIP > 1,0	La variable tiene una alta importancia en la explicación de la variabilidad en las respuestas. En general, las variables con valores VIP mayores a 1 son consideradas significativas para el modelo.
VIP = 1,0	La variable tiene una importancia moderada. Contribuye al modelo, pero no es tan significativa como las variables con VIP mayores.
VIP < 1,0	La variable tiene una baja importancia en el modelo. Puede ser considerada menos relevante en la explicación de la variabilidad en las respuestas.

En las figuras a continuación (29 y 30) se puede observar la métrica VIP para las 207 variables que son objeto de estudio en cada etapa.




Figura 29 Importancia de la variable en la proyección en la etapa de plantilla (a) campaña 1 (b) campaña 2 (c) campaña 3 (d) campaña 4 **Fuente:** Autores




Figura 30 Importancia de la variable en la proyección en la etapa de soca (a) campaña 5 (b) campaña 6 (c) campaña 7 (d) campaña 8 **Fuente:** Autores

A continuación, se presenta los mejores 5 resultados por campaña en cada etapa para la métrica “importancia de la variable en la proyección”, tabla 15 y 16.

Tabla 15 Resultados significativos VIP en el ciclo de plantilla **Fuente:** Autores

CAMPAÑA	TIPO	ÍNDICE	BANDAS	VIP
1	ENTROPIA	Clrededge	BORDE ROJO-NIR	2.110
	PROMEDIO	GNDRE	VERDE-BORDE ROJO	1.872
	CORRELACION	CI	ROJO-AZUL	1.818
	SEGUNDO MOMENTO	MSAVI	ROJO-NIR	1.769
	SEGUNDO MOMENTO	GNDRE	VERDE-BORDE ROJO	1.739
2	CORRELACION	NDI	ROJO-VERDE	3.282
	CORRELACION	GLI	ROJO-VERDE-AZUL	3.267
	CORRELACION	ExG	ROJO-VERDE-AZUL	3.267
	CORRELACION	NGRDI	ROJO-VERDE	3.232
	ENTROPIA	ClGreen	VERDE-NIR	2.789
3	VARIANZA	EVI	ROJO-AZUL-NIR	3.303
	DISIMILITUD	EVI	ROJO-AZUL-NIR	3.060
	HOMOGENEIDAD	CI	ROJO-AZUL	2.630
	CORRELACION	GNDRE	VERDE-BORDE ROJO	2.335
	SEGUNDO MOMENTO	RDVI	ROJO-NIR	2.207
4	CORRELACION	VARI	ROJO-VERDE-AZUL	2.052
	SEGUNDO MOMENTO	EVI	ROJO-AZUL-NIR	1.632
	CORRELACION	GNDVI	ROJO-VERDE	1.490
	CONTRASTE	Clrededge	BORDE ROJO-NIR	1.488
	ENTROPIA	CCCI	ROJO-BORDE ROJO-NIR	1.456

Tabla 16 Resultados significativos VIP en el ciclo de soca **Fuente:** Autores

CAMPAÑA	TIPO	ÍNDICE	BANDAS	VIP
5	VEGETATIVO	CVI	ROJO - VERDE - NIR	2.016
	VEGETATIVO	TGI	ROJO - VERDE - AZUL	1.906
	VEGETATIVO	CCCI	ROJO - BORDE ROJO - NIR	1.651
	VARIANZA	MSAVI	ROJO - NIR	1.603
	VARIANZA	CI	ROJO - AZUL	1.582
6	CORRELACION	ENDVI	VERDE - AZUL - NIR	2.243
	CORRELACION	CVI	ROJO - VERDE - NIR	2.115
	CONTRASTE	TVI	ROJO-NIR	1.862
	CONTRASTE	MSAVI	ROJO - NIR	1.791
	VEGETATIVO	CVI	ROJO - VERDE - NIR	1.756
7	VARIANZA	EVI	ROJO - AZUL - NIR	2.225
	CONTRASTE	CI	ROJO - AZUL	1.645
	VEGETATIVO	ENDVI	VERDE - AZUL - NIR	1.554
	CONTRASTE	EVI	ROJO - AZUL - NIR	1.553
	CONTRASTE	VARI	ROJO - VERDE - AZUL	1.551
8	CORRELACION	MSAVI	ROJO - NIR	2.327
	CORRELACION	VIOPT	AZUL - NIR	2.315
	CORRELACION	RDVI	ROJO - NIR	2.148
	HOMOGENEIDAD	CCCI	ROJO - BORDE ROJO - NIR	2.085
	SEGUNDO MOMENTO	VIOPT	AZUL - NIR	1.962

El análisis de importancia de la variable en la proyección (VIP) permitió identificar los índices espectrales más influyentes en la estimación de Nc mediante el modelo PLS. Los resultados muestran que los índices que combinan las regiones del rojo, borde rojo y el infrarrojo cercano (NIR) presentaron una mayor contribución, coincidiendo con el comportamiento observado en los coeficientes de regresión. En ambos ciclos objeto de estudio (plantilla y soca), la región del NIR mostró una mayor densidad de índices altamente influyentes.

En el ciclo de plantilla y soca la mayoría de los índices considerados de alta contribución por los coeficientes se encontraron también en el análisis VIP (considerando sus respectivas variantes de textura) esto se debe a que los coeficientes de regresión representan la importancia de cada variable explicativa en la predicción de las variables de respuesta, y el VIP representa el valor de cada variable explicativa en el ajuste del modelo tanto para variables de respuesta o dependientes (Márquez, 2017).

Es destacable que los índices de textura fueron los que mayormente contribuyeron a la estimación de Nc. Estos resultados estuvieron en concordancia con Zheng et al. (2020) y Li et al. (2024), quienes encontraron que, los índices de textura, obtenidos a partir de la distribución y variación de los píxeles en imágenes UAV, brindan información sobre la densidad de las plantas, el índice de área foliar y la estructura tridimensional de los cultivos. Los índices de textura superan las limitaciones de los índices de vegetación tradicionales, especialmente en doseles densos, siendo más precisos y sensibles para reflejar variables biofísicas. En las primeras etapas de crecimiento, las métricas de textura capturan cambios de color en las hojas (asociados al crecimiento y absorción de nitrógeno) ofreciendo una mejor comprensión del estado nutricional del cultivo (Li et al., 2024).

Vale la pena mencionar que solo en la región del verde y del rojo, la reflectancia es sensible a la variación de la clorofila, esto se debe a que los coeficientes de absorción de la clorofila en estas regiones del espectro electromagnético son suficientemente bajas para permitir que la luz penetre profundamente en la hoja, y por tanto, la sensibilidad de la absorción y la reflectancia a estas longitudes de onda es máxima, permitiendo una evaluación muy precisa del contenido de clorofila (Cordon, 2009).

8. CONCLUSIONES

La implementación de todos los datos de reflectancia encontrados para las distintas parcelas permite correlacionar de mejor forma la estimación de nitrógeno, dado que evidencia como se realiza la recolección de hojas o muestras en la plantación.

Los índices de textura de tipo “correlación” son los más influyentes en el ciclo de plantilla con correlaciones (ρ) > 0.54 y una alta participación de dicha variante tanto en los coeficientes de regresión como en el VIP. En soca se tuvieron buenos resultados con $R^2 \geq 0.735$ y $RMSEr \leq 9.51\%$ sin predominancia específica sobre algún índice espectral.

El ciclo óptimo para la obtención y extracción de datos para estimar el contenido de nitrógeno en la caña de azúcar variedad CC-00-1940 es el ciclo de plantilla con una varianza explicada superior a 75.6% ($R^2 \geq 0.75$) bajo un error cuadro medio relativo inferior al 13.395%, incluyendo la primer campaña del ciclo de soca (95 DDC) que obtuvo un $R^2 = 0.935$ y $RMSEr = 9.51\%$.

Los índices que involucran las bandas rojo, borde rojo y NIR son los más representativos para el modelo, encontrando dichas bandas en la mayoría de los índices con $VIP > 1.0$ donde las variantes de textura mejoran el modelo PLS a la hora de estimar el contenido de nitrógeno, presentando mejor rendimiento que los índices espectrales tradicionales.

9. RECOMENDACIONES

De acuerdo con los resultados obtenidos, los índices compuestos por bandas de la región del espectro visible presentan una alta participación en el modelo PLS, por lo que se recomienda realizar más estudios dirigidos a esta región, dado que podría tener un gran potencial para estimar nitrógeno.

Se recomienda continuar con esta línea de investigación, ya que las imágenes multiespectrales muestran un gran potencial para el control, monitoreo de la salud y estado nutricional de grandes extensiones de cultivo. Adicionalmente, el modelo de regresión por mínimos cuadrados parciales es útil para este propósito, pero también se podría analizar con modelos impulsados por inteligencia artificial.

Se recomienda ampliar la base de datos con información del mismo tipo de cultivo, y robustecer así la parte estadística para detectar cambios de sensibilidad en cada índice espectral en las distintas etapas de crecimiento del cultivo.

10. REFERENCIAS BIBLIOGRÁFICAS

- Abad, G. (2023). Análisis de la firma espectral de *Cistus ladanifer* L., a través del seguimiento con datos de teledetección. Recuperado de <https://uvadoc.uva.es/handle/10324/68036>
- Agisoft Metashape. (2023). MicaSense RedEdge MX processing workflow (including Reflectance Calibration) in Agisoft Metashape Professional. Recuperado 23 de septiembre de 2024, de Helpdesk Portal website:
<https://agisoft.freshdesk.com/support/solutions/articles/31000148780-micasense-rededge-mx-processing-workflow-including-reflectance-calibration-in-agisoft-metashape-pro>
- Aguilar Rivera, N. (2011). Competitividad de la agroindustria azucarera de la Huasteca México. Recuperado de <https://repositorioinstitucional.uaslp.mx/xmlui/handle/i/3560>
- Aguilar Rivera, N. (2015). Percepción remota como herramienta de competitividad de la agricultura. *Revista mexicana de ciencias agrícolas*, 6(2), 399-405.
- Ahamed, T., Tian, L., Zhang, Y., & Ting, K. C. (2011). A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, 35(7), 2455-2469.
<https://doi.org/10.1016/j.biombioe.2011.02.028>
- Akbarian, S., Xu, C., Wang, W., Ginns, S., & Lim, S. (2022). Sugarcane yields prediction at the row level using a novel cross-validation approach to multi-year multispectral images. *Computers and Electronics in Agriculture*, 198, 107024. <https://doi.org/10.1016/j.compag.2022.107024>
- Amaral, L. R., Molin, J. P., & Schepers, J. S. (2015). Algorithm for Variable-Rate Nitrogen Application in Sugarcane Based on Active Crop Canopy Sensor. *Agronomy Journal*, 107(4), 1513-1523. <https://doi.org/10.2134/agronj14.0494>
- Arrogante, P. (2017). Multi-Angle Imaging Spectroradiometer (MISR): Análisis de la calidad de sus datos, variabilidad espacio-temporal en la España Peninsular y su uso en la estimación de variables forestales apoyado en datos LiDAR e inventario de campo. Recuperado de <https://eciencia.urjc.es/handle/10115/14745>

- Asocaña. (2024, junio 25). Informe Anual 2023-2024. Recuperado 17 de noviembre de 2024, de Asocaña—Sector Agroindustrial de la Caña website:
<http://www.asocana.org/modules/documentos/17710.aspx>
- Astaoui, G., Dadaiss, J. E., Sebari, I., Benmansour, S., & Mohamed, E. (2021). Mapping Wheat Dry Matter and Nitrogen Content Dynamics and Estimation of Wheat Yield Using UAV Multispectral Imagery Machine Learning and a Variety-Based Approach: Case Study of Morocco. *AgriEngineering*, 3(1), 29-49. <https://doi.org/10.3390/agriengineering3010003>
- Baijnath-Rodino, J. A., Martinez, A., York, R. A., Foufoula-Georgiou, E., AghaKouchak, A., & Banerjee, T. (2023). Quantifying the effectiveness of shaded fuel breaks from ground-based, aerial, and spaceborne observations. *Forest Ecology and Management*, 543, 121142. <https://doi.org/10.1016/j.foreco.2023.121142>
- Bannari, A., Kadhem, G., El-Battay, A., Hameid, N. A., & Rouai, M. (2016). Assessment of Land Erosion and Sediment Accumulation Caused by Runoff after a Flash-Flooding Storm Using Topographic Profiles and Spectral Indices. *Advances in Remote Sensing*, 5(4), 315-354. <https://doi.org/10.4236/ars.2016.54024>
- Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13(1-2), 95-120. <https://doi.org/10.1080/02757259509532298>
- Barbasiewicz, A., Widorski, T., & Daliga, K. (2018). The analysis of the accuracy of spatial models using photogrammetric software: Agisoft Photoscan and Pix4D. *E3S Web of Conferences*, 26, 00012. <https://doi.org/10.1051/e3sconf/20182600012>
- Baresel, J. P., Rischbeck, P., Hu, Y., Kipp, S., Hu, Y., Barmerier, G., ... Schmidhalter, U. (2017). Use of a digital camera as alternative method for non-destructive detection of the leaf chlorophyll content and the nitrogen nutrition status in wheat. *Computers and Electronics in Agriculture*, 140, 25-33. <https://doi.org/10.1016/j.compag.2017.05.032>
- Barrera, M. A. M. (2014). Uso de la correlación de spearman en un estudio de intervención en fisioterapia. *Movimiento científico*, 8(1), 98-104. <https://doi.org/10.33881/2011-7191.mct.08111>

- Bassine, F. Z., Errami, A., & Khaldoun, M. (2019). Vegetation Recognition Based on UAV Image Color Index. 2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 1-4. <https://doi.org/10.1109/EEEIC.2019.8783830>
- Bastidas Guayasamín, G. A., & Naranjo Moina, E. M. (2022). Desarrollo de una metodología para la identificación de la sintomatología de fusarium raza 1 en banano mediante el uso de sensores aéreos no tripulados (bachelorThesis, Universidad de las Fuerzas Armadas ESPE. Carrera de Ingeniería Geográfica y del Medio Ambiente). Universidad de las Fuerzas Armadas ESPE. Carrera de Ingeniería Geográfica y del Medio Ambiente. Recuperado de <http://repositorio.espe.edu.ec/jspui/handle/21000/28970>
- Bohórquez, A., Puentes, Y., & Menjivar, J. C. (2014). Evaluación de la calidad del compost producido a partir de subproductos agroindustriales de caña de azúcar. Ciencia y Tecnología Agropecuaria, 15(1), 73-81. https://doi.org/10.21930/rcta.vol15_num1_art:398
- Broge, N. H., & Leblanc, E. (2001). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. Remote Sensing of Environment, 76(2), 156-172. [https://doi.org/10.1016/S0034-4257\(00\)00197-8](https://doi.org/10.1016/S0034-4257(00)00197-8)
- Buenaño Haro, D. W. (2009). Influencia del método de plantación en el crecimiento inicial de la caña de Azúcar (Sacharum SPP.) Cultivar limeña en suelos del orden inceptisoles de Pastaza. (BachelorThesis). Recuperado de <https://repositorio.uea.edu.ec/handle/123456789/46>
- Buschmann, C., & Nagel, E. (1993). In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. International Journal of Remote Sensing, 14(4), 711-722. <https://doi.org/10.1080/01431169308904370>
- Cárdenas Navarro, R., Sanchez-Yañez, J., Farías-Rodríguez, R., & Peña Cabriales, J. (2004). Contribution of nitrogen to agriculture. Revista Chapingo Serie Horticultura, 10, 173-178. <https://doi.org/10.5154/r.rchsh.2002.07.039>
- Carrillo, V., & Villegas, A. A. (s. f.). Servicio de Cooperación Técnica y Transferencia de Tecnología. CENICAÑA.

- Celaya, H., & Castellanos, A. (2011). Mineralización de nitrógeno en el suelo de zonas áridas y semiáridas. 29, 343-356.
- Cenicaña. (2012). Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia – Cenicaña. Recuperado 25 de septiembre de 2024, de <https://www.cenicana.org/principios-y-aplicaciones-de-la-percepcion-remota-en-el-cultivo-de-la-cana-de-azucar-en-colombia/>
- Cenicaña. (2020). El genoma de la variedad CC 01-1940 y su importancia para la industria azucarera colombiana | Webinar – Cenicaña. Recuperado 27 de octubre de 2023, de <https://www.cenicana.org/eventos/el-genoma-de-la-variedad-cc-01-1940-y-su-importancia-para-la-industria-azucarera-colombiana-webinar/>
- Cenicaña. (2025). Análisis de tejido foliar para recomendaciones de fertilización – Cenicaña. Recuperado 17 de marzo de 2025, de <https://www.cenicana.org/servicio-de-analisis-de-tejido-foliar-para-recomendaciones-de-fertilizacion-3/>
- Chang, J., & Huang, C. (2024). Three decades of spatiotemporal dynamics in forest biomass density in the Qinba Mountains. *Ecological Informatics*, 81. Scopus. <https://doi.org/10.1016/j.ecoinf.2024.102566>
- Clarke, T. R., Moran, M. S., Barnes, E. M., Pinter, P. J., & Qi, J. (2001). Planar domain indices: A method for measuring a quality of a single component in two-component pixels. *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No.01CH37217)*, 3, 1279-1281. Sydney, NSW, Australia: IEEE. <https://doi.org/10.1109/IGARSS.2001.976818>
- Colorado, J. D., Cera-Bornacelli, N., Caldas, J. S., Petro, E., Rebolledo, M. C., Cuellar, D., ... Jaramillo-Botero, A. (2020). Estimation of Nitrogen in Rice Crops from UAV-Captured Images. *Remote Sensing*, 12(20), 3396. <https://doi.org/10.3390/rs12203396>
- Cordon, G. B. (2009). Métodos ópticos no destructivos para monitoreo de salud vegetal (Tesis Doctoral, Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales). Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales. Recuperado de https://bibliotecadigital.exactas.uba.ar/collection/tesis/document/tesis_n4575_Cordon

- Díaz, F. (2020). Incidencia de las condiciones socio-económicas en las solicitudes ciudadanas (Tesis Especialización, Universidad de Buenos Aires. Facultad de Ciencias Económicas).
Universidad de Buenos Aires. Facultad de Ciencias Económicas, Buenos Aires. Recuperado de http://bibliotecadigital.econ.uba.ar/download/tpos/1502-1914_DiazF.pdf
- Escobar, O. F. (2015). Respuestas espectrales a la fertilización Con nitrógeno y potasio en el cultivo del Banano (musa aaa simmonds), caso Municipio Zona Bananera. Recuperado de <https://www.semanticscholar.org/paper/Respuestas-espectrales-a-la-fertilizaci%C3%B3n-Con-y-en-Pardo-Fradique/8c063524c323c4235beaec11f4447124fff96c54>
- Estupinan Silva, R., & Quesada, B. (2011). El Proceso Haber-Bosch En La Sociedad Agroindustrial: Peligros Y Alternativas (The Haber-Bosch Process in the Agro-Industrial Society: Dangers and Alternatives) [SSRN Scholarly Paper]. Rochester, NY. Recuperado de <https://papers.ssrn.com/abstract=2568323>
- Fedesarrollo. (2018). ESTUDIO SOBRE EL IMPACTO SOCIOECONÓMICO DEL SECTOR AGROINDUSTRIAL DE LA CAÑA EN COLOMBIA. FEDESARROLLO, 84.
- Filella, I., Serrano, L., Serra, J., & Peñuelas, J. (1995). Evaluating Wheat Nitrogen Status with Canopy Reflectance Indices and Discriminant Analysis. *Crop Science*, 35(5), crops1995.0011183X003500050023x.
<https://doi.org/10.2135/cropsci1995.0011183X003500050023x>
- Filla, V. A., Coelho, A. P., Bettiol, J. V. T., Leal, F. T., Lemos, L. B., & Rosalen, D. L. (2023). Model performance in estimating the yield of common bean cultivars. *Revista Ciência Agronômica*, 54(0), 1-10. <https://doi.org/10.5935/1806-6690.20230002>
- Finagro. (2018). FICHA DE INTELIGENCIA - CAÑA DE AZÚCAR (p. 14). Colombia: Fondo para el Financiamiento del Sector Agropecuario. Recuperado de Fondo para el Financiamiento del Sector Agropecuario website: https://www.finagro.com.co/sites/default/files/node/basic-page/files/ficha_cana_de_azucar_version_ii_1.pdf
- Fitzgerald, G., Rodriguez, D., & O'Leary, G. (2010). Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). *Field Crops Research*, 116(3), 318-324. <https://doi.org/10.1016/j.fcr.2010.01.010>

- Franco, E. B., & Arjona, M. (2021). EVALUACIÓN DE DOS MODELOS DE PREDICCIÓN DEL CONTENIDO DE PROTEÍNA CRUDA EN HARINA DE SOYA MEDIANTE LA TÉCNICA NIRS. *Revista Investigaciones Agropecuarias*, 3(2), 57-67.
- Galindez, C. A. (2022). Clasificación del estado nutricional por Nitrógeno de un cultivo de caña de azúcar por medio del análisis wavelet de información hiperspectral de dosel. *INGENIERÍA Y COMPETITIVIDAD*, 24(1). <https://doi.org/10.25100/iyc.v24i1.11211>
- Gilabert, M. A., Gonzalez, J., & García, J. (1997). Acerca de los índices de vegetación. *Revista de teledetección: Revista de la Asociación Española de Teledetección*, ISSN 1133-0953, N°. 8, 1997, 8. Recuperado de https://www.researchgate.net/publication/39195330_Acerca_de_los_indices_de_vegetacion
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Goel, N. S., & Qin, W. (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. *Remote Sensing Reviews*, 10(4), 309-347. <https://doi.org/10.1080/02757259409532252>
- Hancock, D. W., & Dougherty, C. T. (2007). Relationships between Blue- and Red-based Vegetation Indices and Leaf Area and Yield of Alfalfa. *Crop Science*, 47(6), 2547-2556. <https://doi.org/10.2135/cropsci2007.01.0031>
- Hassan, M. A., Yang, M., Rasheed, A., Yang, G., Reynolds, M., Xia, X., ... He, Z. (2019). A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform. *Plant Science: An International Journal of Experimental Plant Biology*, 282, 95-103. <https://doi.org/10.1016/j.plantsci.2018.10.022>
- Hassani, K., Gholizadeh, H., Taghvaeian, S., Natalie, V., Carpenter, J., & Jacob, J. (2023). Application of UAS-Based Remote Sensing in Estimating Winter Wheat Phenotypic Traits and Yield During the Growing Season. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 91(2), 77-90. <https://doi.org/10.1007/s41064-022-00229-5>

- Hoss, D. F., Luz, G. L. da, Lajús, C. R., Moretto, M. A., & Tremea, G. A. (2020). Multispectral aerial images for the evaluation of maize crops. *Ciência e Agrotecnologia*, 44, e004920.
<https://doi.org/10.1590/1413-7054202044004920>
- Huarquilla H., W. A. (2022). Modelos de predicción del rendimiento de la caña de azúcar a partir de índices multiespectrales de vegetación en Honduras (Zamorano: Escuela Agrícola Panamericana, 2022). Zamorano: Escuela Agrícola Panamericana, 2022. Recuperado de <https://hdl.handle.net/11036/7210.2>
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Hunt Jr., E. R., Daughtry, C. S. T., Eitel, J. U. H., & Long, D. S. (2011). Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agronomy Journal*, 103(4), 1090-1099.
<https://doi.org/10.2134/agronj2010.0395>
- Hurtado Villafañe, A. M., & Perafán Trullo, O. J. (2019). Estimación del nitrógeno foliar en caña de azúcar (*saccharum officinarum*) mediante el uso de espectroscopia óptica [recurso electrónico] (Universidad del Valle). Universidad del Valle, Cali, Colombia. (Biblioteca Mario Carvajal - Melendez - Cali 3745). Recuperado de <https://bd.univalle.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=cat07246a&AN=udv.979112&lang=es&site=eds-live>
- IBM. (2024, febrero 8). SPSS Statistics 29.0.0. Recuperado 25 de septiembre de 2024, de <https://www.ibm.com/docs/es/spss-statistics/29.0.0?topic=sales-output-independent-variables>
- Inoue, Y., Sakaiya, E., Zhu, Y., & Takahashi, W. (2012). Diagnostic mapping of canopy nitrogen content in rice based on hyperspectral measurements. *Remote Sensing of Environment*, 126, 210-221. <https://doi.org/10.1016/j.rse.2012.08.026>
- Jiménez Guerrero, M. del P. (2008). Extracción de características de textura basada en la transformada wavelet discreta. (Universidad de Sevilla). Universidad de Sevilla. Recuperado de <https://biblus.us.es/bibing/proyectos/abreproy/11494>

- Jiménez, S. I. J., Bustamante, W. O., de Jesús, M., & Pablo, M. (2019). INFORMACIÓN DE DRONES Y SU ANÁLISIS EN LA AGRICULTURA DE PRECISIÓN. Colegio Mexicano de Ingenieros en Irrigación A.C., 16.
- Lafaye de Micheaux, P., Drouilhet, R., & Liquet, B. (2014). The R Software: Fundamentals of Programming and Statistical Analysis.
- Lee, J.-H., & Sull, S. (2019). Regression Tree CNN for Estimation of Ground Sampling Distance Based on Floating-Point Representation. *Remote Sensing*, 11(19), 2276. <https://doi.org/10.3390/rs11192276>
- Lee, K., Kim, B., & Park, S. (2023). Evaluating the potential of burn severity mapping and transferability of Copernicus EMS data using Sentinel-2 imagery and machine learning approaches. *GIScience & Remote Sensing*, 60(1), 2192157. <https://doi.org/10.1080/15481603.2023.2192157>
- Legato, A. M., & Alonso, A. H. (2013). Resultados óptimos demandan herramientas de mayor precisión: El aporte de Mínimos Cuadrados Parciales (PLS). *Revista de la Facultad de Ciencias Económicas*, no. 10. <https://doi.org/10.30972/rfce.0101102>
- Li, C., Li, X., Meng, X., Xiao, Z., Wu, X., Wang, X., ... Yang, C. (2023). Hyperspectral Estimation of Nitrogen Content in Wheat Based on Fractional Difference and Continuous Wavelet Transform. *Agriculture*, 13(5), 1017. <https://doi.org/10.3390/agriculture13051017>
- Li, M., Liu, Y., Lu, X., Jiang, J., Ma, X., Wen, M., & Ma, F. (2024). Integrating Unmanned Aerial Vehicle-Derived Vegetation and Texture Indices for the Estimation of Leaf Nitrogen Concentration in Drip-Irrigated Cotton under Reduced Nitrogen Treatment and Different Plant Densities. *Agronomy*, 14(1), 120. <https://doi.org/10.3390/agronomy14010120>
- Li, Xiaoxin, Hu, C., Delgado, J. A., Zhang, Y., & Ouyang, Z. (2007). Increased nitrogen use efficiencies as a key mitigation alternative to reduce nitrate leaching in north china plain. *Agricultural Water Management*, 89(1), 137-147. <https://doi.org/10.1016/j.agwat.2006.12.012>
- Li, Xingchen, Liu, L., & Huang, L. (2020). COMPARISON OF SEVERAL REMOTE SENSING IMAGE CLASSIFICATION METHODS BASED ON ENVI. *The International Archives of*

- the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-3-W10, 605-611. <https://doi.org/10.5194/isprs-archives-XLII-3-W10-605-2020>
- Manzo Cruz, F., & Arzate Hernández, L. (2019). Sistema de Semáforos Inteligentes para el Control de Tráfico Vehicular. Recuperado de <http://ri.uaemex.mx/handle/20.500.11799/99060>
- Marcussi, A. B., Bueno, C. R. P., Miqueloni, D. P., & Arraes, C. L. (2010). UTILIZAÇÃO DE INDICES DE VEGETAÇÃO PARA OS SISTEMAS DE INFORMAÇÃO GEOGRAFICA. Caminhos de Geografia, 11(35), 41-53. <https://doi.org/10.14393/RCG113516000>
- Márquez Ruiz, C. (2017). Modelo de regresión PLS. Recuperado de <http://hdl.handle.net/11441/63208>
- Martínez, R. M., Tuya Pendás, L. C., Martínez Ortega, M., Pérez Abreu, A., & Cánovas, A. M. (2009). EL COEFICIENTE DE CORRELACION DE LOS RANGOS DE SPEARMAN CARACTERIZACION. Revista Habanera de Ciencias Médicas, 8(2), 0-0.
- Mekik, C., & Arslanoglu, M. (2009). Investigation on Accuracies of Real Time Kinematic GPS for GIS Applications. Remote Sensing, 1(1), 22-35. <https://doi.org/10.3390/rs1010022>
- Mendivelso, F. (2021). Prueba no paramétrica de correlación de Spearman. Revista Médica Sanitas, 24(1). <https://doi.org/10.26852/01234250.578>
- Mesa, C. A., & Silva, C. A. (2015). Estudio de la relación entre la fertilización nitrogenada y la reflectancia espectral en el cultivo de la papa (*solanum tuberosum* L.). http://unicornio.utadeo.edu.co/tesis/maestria_cambiantales/T061.pdf. <https://doi.org/10.1766>
- Messina, G., Badagliacca, G., Praticò, S., Preiti, G., Monti, M., & Modica, G. (2023). Multispectral UAV-Based Monitoring of Behavior of Different Wheat and Barley Varieties. En V. Ferro, G. Giordano, S. Orlando, M. Vallone, G. Cascone, & S. M. C. Porto (Eds.), AIIA 2022: Biosystems Engineering Towards the Green Deal (pp. 1173-1181). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-30329-6_121
- MicaSense. (2022, junio 7). MicaSense Knowledge Base—RedEdge User Manual (PDF)—Legacy. Recuperado 27 de junio de 2023, de MicaSense Knowledge Base website: <https://support.micasense.com/hc/en-us/articles/215261448-RedEdge-User-Manual-PDF-Legacy>

- Miphokasap, P., Honda, K., Vaiphasa, C., Souris, M., & Nagai, M. (2012). Estimating Canopy Nitrogen Concentration in Sugarcane Using Field Imaging Spectroscopy. *Remote Sensing*, 4(6), 1651-1670. <https://doi.org/10.3390/rs4061651>
- Moreno, J. C., Landeros Sánchez, C., Vázquez, A. P., Palacios-Vélez, O. L., Chávez, M. D. R. C., & Collado, C. J. L. (2016). Manejo y actitud del productor sobre la fertilización nitrogenada en caña de azúcar: Un estudio de caso. *RINDERESU*, 1(1), 26-34.
- Murillo Sandoval, P. J., & Carbonell González, J. A. (2012). Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia. Cali, Colombia: Centro de Investigación de la Caña de Azúcar de Colombia : Departamento Administrativo de Ciencia, Tecnología e Innovación. Recuperado de https://www.cenicana.org/pdf_privado/documentos_no_seridados/libro_percepcion_remota/principios-y-aplicaciones_percepcion-remota.pdf
- Olivares, B. O., & López, M. A. (2019). Índice de Vegetación de Diferencia Normalizada aplicado al territorio indígena agrícola de Kashaama, Venezuela. *Cuadernos de Investigación UNED*, 11(2), 112-121. <https://doi.org/10.22458/urj.v11i2.2299>
- Patanè, L., Graziani, S., & Xibilia, M. G. (2025). Identification of finite-time delay and regressors for the design of soft sensors in the presence of input collinearity. *Control Engineering Practice*, 157, 106267. <https://doi.org/10.1016/j.conengprac.2025.106267>
- Pérez, D. D. (2022). Metodología para la estimación de la biomasa aérea y stock de carbono por medio de sensores remotos. Recuperado de <https://bibliotecadigital.univalle.edu.co/entities/publication/7cb92eab-65c5-4826-ad2a-9c7eac19801e>
- Portz, G., Amaral, L. R., Molin, J. P., & Adamchuk, V. I. (2013). Field comparison of ultrasonic and canopy reflectance sensors used to estimate biomass and N-uptake in sugarcane. En J. V. Stafford (Ed.), *Precision agriculture '13* (pp. 111-117). Wageningen: Academic Publishers. https://doi.org/10.3920/978-90-8686-778-3_12
- Prasert, S. (2005). MULTI ANGLE IMAGING WITH SPECTRAL REMOTE SENSING FOR SCENE CLASSIFICATION.

- Presutti, M. (2004). LA MATRIZ DE CO-OCURRENCIA EN LA CLASIFICACIÓN MULTIESPECTRAL: TUTORIAL PARA LA ENSEÑANZA DE MEDIDAS TEXTURALES EN CURSOS DE GRADO UNIVERSITARIO. 9.
- Puerto, C. E. (2020). Caracterización de la mancha de asfalto en maíz (*Zea mays* L.) mediante el uso de herramientas de detección y control en condiciones de campo. *Escuela Agrícola Panamericana*, 55.
- Purón, R. J. H., Lauzardo, J. F., Sopeña, E. P., & Martínez, R. J. D. (2010). Desarrollo de un sistema automatizado para mediciones de espectroscopía óptica. *Revista Ingeniería Electrónica, Automática y Comunicaciones* ISSN: 1815-5928, 31(3), 8-14.
- Puth, M.-T., Neuhäuser, M., & Ruxton, G. D. (2015). Effective use of Spearman's and Kendall's correlation coefficients for association between two measured traits. <https://doi.org/10.1016/j.anbehav.2015.01.010>
- Raddi, S., Giannetti, F., Martini, S., Farinella, F., Chirici, G., Tani, A., ... Mariotti, B. (2022). Monitoring drought response and chlorophyll content in *Quercus* by consumer-grade, near-infrared (NIR) camera: A comparison with reflectance spectroscopy. *New Forests*, 53(2), 241-265. <https://doi.org/10.1007/s11056-021-09848-z>
- Ramirez, C. A. M. (2020). Sector Agroindustrial de la Caña. Recuperado 15 de marzo de 2023, de Asocaña—Sector Agroindustrial de la Caña website: <https://www.asocana.org/publico/info.aspx?Cid=215>
- Reyes, A., Daza, M. C., Galindez Jamioy, C. A., Rosero García, E. E., Muñoz Arboleda, F., & Solarte Rodríguez, E. (2021). Estimating canopy nitrogen concentration of sugarcane crop using in situ spectroscopy. *Heliyon*, 7(3), e06566. <https://doi.org/10.1016/j.heliyon.2021.e06566>
- Reyes, A., Solarte Rodríguez, E., & Muñoz Arboleda, F. (2020). Bioindicadores espectrales para monitoreo del cultivo de caña de azúcar en condiciones de tensión ambiental por disponibilidad de nitrógeno. Universidad del Valle. (Biblioteca Mario Carvajal - Melendez - Cali 9706 R457).

- Reyniers, M., Walvoort, D., & Baardemaaker. (2006). A linear model to predict with a multi-spectral radiometer the amount of nitrogen in winter wheat. *International Journal of Remote Sensing* 27 (2006) 19, 27. <https://doi.org/10.1080/01431160600791650>
- Rincón, C. (2013). Aspectos jurídicos relativos a la utilización del espectro electromagnético y radioeléctrico y su importancia en las telecomunicaciones por satélite. *Revista de Derecho Público*, (30), 1-28. <https://doi.org/10.15425/redepub.30.2013.13>
- Rojas, O. Y. (2023). Evaluación de la relación entre el estado nutricional y la respuesta espectral del cultivo de papa (*Solanum tuberosum* L.) para la estimación del contenido de nitrógeno y potasio (Trabajo de grado - Maestría, Universidad Nacional de Colombia). Universidad Nacional de Colombia. Recuperado de <https://repositorio.unal.edu.co/handle/unal/86752>
- Samborski, S. M., Torres, U., Bech, A., Leszczyńska, R., & Bagavathiannan, M. V. (2024). A Case Study on The Evaluation of Maturity Class in Potato Breeding Trials Using UAV Imagery. *American Journal of Potato Research*. Scopus. <https://doi.org/10.1007/s12230-024-09965-3>
- Sarasti, O. A. O., & Ramírez, G. L. (2016). Sistemas de Información enfocados en tecnologías de agricultura de precisión y aplicables a la caña de azúcar, una revisión. *Revista Ingenierías Universidad de Medellín*, 15(28), 103-124. <https://doi.org/10.22395/rium.v15n28a6>
- Serway, A. R., & Jewett, J. (2018). *Física para ciencias e ingeniería* (Vol. 2). Cengage Learning. Recuperado de <https://www-ebooks7-24-com.bd.univalle.edu.co/stage.aspx?il=784&pg=&ed=>
- Strong, C. J., Burnside, N. G., & Llewellyn, D. (2017). The potential of small-Unmanned Aircraft Systems for the rapid detection of threatened unimproved grassland communities using an Enhanced Normalized Difference Vegetation Index. *PLOS ONE*, 12(10), e0186193. <https://doi.org/10.1371/journal.pone.0186193>
- Stroppiana, D., Boschetti, M., Brivio, P. A., & Bocchi, S. (2009). Plant nitrogen concentration in paddy rice from field canopy hyperspectral radiometry. *Field Crops Research*, 111(1), 119-129. <https://doi.org/10.1016/j.fcr.2008.11.004>

- Szeląg, B., Sobura, S., & Stoińska, R. (2023). Application of Multispectral Images from Unmanned Aerial Vehicles to Analyze Operations of a Wastewater Treatment Plant. *Energies*, 16(6), 2871. <https://doi.org/10.3390/en16062871>
- Tafolla, R. O. M. (2021). Estimación del estado nutrimental de nitrógeno mediante métodos no destructivos en lechuga, albahaca y arúgula. Recuperado de <http://riaa.uaem.mx/xmlui/handle/20.500.12055/1896>
- Takasu, T., & Yasuda, A. (2009). Development of the low-cost RTK-GPS receiver with an open source program package RTKLIB. *International Symposium on GPS/GNSS*.
- Tovar, A. L. (2019). Estimación de biomasa aérea de eucalipto (*Eucalyptus grandis*) y pino (*Pinus* spp) en plantaciones forestales comerciales, usando imágenes satelitales Sentinel (Trabajo de grado - Maestría, Universidad Nacional de Colombia). Universidad Nacional de Colombia. Recuperado de <https://repositorio.unal.edu.co/handle/unal/69838>
- Tucker, C. J., Elgin, J. H., McMurtrey, J. E., & Fan, C. J. (1979). Monitoring corn and soybean crop development with hand-held radiometer spectral data. *Remote Sensing of Environment*, 8(3), 237-248. [https://doi.org/10.1016/0034-4257\(79\)90004-X](https://doi.org/10.1016/0034-4257(79)90004-X)
- Vincini, M., & Frazzi, E. (2011). Comparing narrow and broad-band vegetation indices to estimate leaf chlorophyll content in planophile crop canopies. *Precision Agriculture*, 12, 334-344. <https://doi.org/10.1007/s11119-010-9204-3>
- Wang, G., Peng, W., Zhang, L., Zhang, J., & Xiang, J. (2023). Vegetation EVI changes and response to natural factors and human activities based on geographically and temporally weighted regression. *Global Ecology and Conservation*, 45, e02531. <https://doi.org/10.1016/j.gecco.2023.e02531>
- Widlowski, J.-L., Verstraete, M. M., Pinty, B., & Gobron, N. (2000). Advanced vegetation indices optimized for up-coming sensors: Design, performance, and applications. *IEEE Transactions on Geoscience and Remote Sensing*, 38(6), 2489-2505. <https://doi.org/10.1109/36.885197>
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Shape features for identifying young weeds using image analysis. *Transactions of the American Society of Agricultural Engineers*, 38(1), 271-281. Scopus. Recuperado de Scopus.

- Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, e1353691. <https://doi.org/10.1155/2017/1353691>
- Xue, Y., Li, Y., Guang, J., Zhang, X., & Guo, J. (2008). Small satellite remote sensing and applications – history, current and future. *International Journal of Remote Sensing*, 29(15), 4339-4372. <https://doi.org/10.1080/01431160801914945>
- Zhang, K., Cao, Q., Song, X., Han, B., Zhang, Y., Liu, X., ... Tian, Y. (2023). Remote sensing approaches for crop nutrition diagnosis and recommendations for nitrogen fertilizers in rice at canopy level. *Archives of Agronomy and Soil Science*, 69(14), 2878-2897. <https://doi.org/10.1080/03650340.2023.2180146>
- Zhang, Z., Ding, J., Wang, J., & Ge, X. (2020). Prediction of soil organic matter in northwestern China using fractional-order derivative spectroscopy and modified normalized difference indices. *CATENA*, 185, 104257. <https://doi.org/10.1016/j.catena.2019.104257>
- Zhao, D., Reddy, K. R., Kakani, V. G., Read, J. J., & Koti, S. (2007). Canopy reflectance in cotton for growth assessment and lint yield prediction. *European Journal of Agronomy*, 26(3), 335-344. <https://doi.org/10.1016/j.eja.2006.12.001>
- Zheng, H., Cheng, T., Li, D., Yao, X., Tian, Y., Cao, W., & Zhu, Y. (2018). Combining Unmanned Aerial Vehicle (UAV)-Based Multispectral Imagery and Ground-Based Hyperspectral Data for Plant Nitrogen Concentration Estimation in Rice. *Frontiers in Plant Science*, 9. Recuperado de <https://www.frontiersin.org/articles/10.3389/fpls.2018.00936>
- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y., ... Yao, X. (2018). A Comparative Assessment of Different Modeling Algorithms for Estimating Leaf Nitrogen Content in Winter Wheat Using Multispectral Images from an Unmanned Aerial Vehicle. *Remote Sensing*, 10(12), 2026. <https://doi.org/10.3390/rs10122026>
- Zheng, H., Ma, J., Zhou, M., Li, D., Yao, X., Cao, W., ... Cheng, T. (2020). Enhancing the Nitrogen Signals of Rice Canopies across Critical Growth Stages through the Integration of Textural and Spectral Information from Unmanned Aerial Vehicle (UAV) Multispectral Imagery. *Remote Sensing*, 12(6), 957. <https://doi.org/10.3390/rs12060957>

11. ANEXOS

Anexo 1 Correlación de Spearman por campaña en etapa de plantilla **Fuente:** Autores

URL:

https://docs.google.com/spreadsheets/d/1mf_rOyppCmgx29LySztS_eVDI5pCJFIJ/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true

Anexo 2 Correlación de Spearman por campaña en etapa de soca **Fuente:** Autores

URL:

https://docs.google.com/spreadsheets/d/1IZZd7WjklL6Z3jz0hXIDjWjCObA6pqZ6/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true

Anexo 3 Código PLS en R **Fuente:** Autores

URL: https://drive.google.com/file/d/1P1EYJl35RTmQmnvnT4L-XZmj-C2XOnFR/view?usp=drive_link

Anexo 4 Código correlación de Spearman en R **Fuente:** Autores

URL: https://drive.google.com/file/d/1TDMZc5iZbiTDAf1zD6pk5N7fl9k1lvun/view?usp=drive_link

Anexo 5 Calculo de índices en etapa de plantilla **Fuente:** Autores

URL:

https://docs.google.com/spreadsheets/d/19PqmdYAIQPUXsOVISbCy4Xyi33sgx9lv/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true

Anexo 6 Calculo de índices en etapa de soca **Fuente:** Autores

URL:

https://docs.google.com/spreadsheets/d/1ZqS6Fi3OwxY7KbxXi4YDVIPySdnAWM1T/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true

Anexo 7 Resultados generales en etapa de plantilla **Fuente:** Autores

URL: [https://docs.google.com/spreadsheets/d/1rGnbxryDhSAnH-](https://docs.google.com/spreadsheets/d/1rGnbxryDhSAnH-FL9xVszYcshlb_IMyy/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true)

[FL9xVszYcshlb_IMyy/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1rGnbxryDhSAnH-FL9xVszYcshlb_IMyy/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true)

Anexo 8 Resultados generales en etapa de soca **Fuente:** Autores

URL:

https://docs.google.com/spreadsheets/d/1R3bjCdZ0tDzWefegvR7WIW2tO8ZkLReT/edit?usp=drive_link&oid=106034447913346601482&rtpof=true&sd=true