

Estimación de nitrógeno foliar en *Zea mays* L. mediante índices de vegetación y sensores multispectrales

Estimation of foliar nitrogen in *Zea mays* L. using vegetation indices and multispectral sensors

Alan Joel Servín-Prieto¹ , José Alfredo Montemayor-Trejo^{1*} , Ramón Trucíos-Caciano² ,
Juan Estrada-Ávalos² , Jorge Arnaldo Orozco-Vidal¹ , Pablo Yescas-Coronado¹ 

¹Tecnológico Nacional de México / Instituto Tecnológico de Torreón. Carretera Torreón–San Pedro de las Colonias Km 7.5, Ejido Ana, CP. 27170. Torreón, Coahuila, México.

²Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. CENID-RASPA. Gómez Palacio, Durango, México.

*Autor de correspondencia: jtmontemayor@hotmail.com

Artículo científico

Recibido: 19 de abril 2025

Aceptado: 03 de julio 2026

RESUMEN. El maíz (*Zea mays* L.) es un cultivo esencial a nivel mundial por su importancia en la seguridad alimentaria y la producción ganadera, cuyo rendimiento depende en gran medida del contenido de nitrógeno (N), nutriente clave en el proceso de la fotosíntesis y el desarrollo del grano. El objetivo del presente estudio fue evaluar la correlación entre diferentes índices de vegetación (IV) y el contenido de N en maíz forrajero híbrido (variedad N83N5), con el fin de optimizar su monitoreo mediante sensores remotos. La investigación se realizó en la Granja Palestina, Francisco I. Madero, Coahuila, México, utilizando imágenes de los sensores Sentinel-2A y 2B, así como del sensor Parrot Sequoia montado en un dron (VANT). Se obtuvieron veintiún índices de vegetación a partir de ambos sensores y se analizaron mediante modelos de regresión y análisis multivariado. Los resultados mostraron que la resolución espacial de las imágenes y la selección de índices de vegetación son determinantes para mejorar la precisión de los modelos de estimación del contenido de N. Para Sentinel-2, el mejor modelo ($R^2 = 0.908$) incluyó cinco índices (CCCI, TCARI/OSAVI RE, TCARI, MSAVI y MTCI), mientras que el sensor Sequoia mostró buen rendimiento con un modelo simple, usando GNDVI ($R^2 = 0.814$), SAVI ($R^2 = 0.829$), MSAVI ($R^2 = 0.826$) y NDVI ($R^2 = 0.834$). Se concluye que la selección del sensor y de los índices espectrales permite desarrollar metodologías precisas para el monitoreo del contenido de N en maíz, contribuyendo al avance de la agricultura de precisión.

Palabras clave: Agricultura de precisión, Modelos de predicción, Parrot Sequoia, Sentinel-2, Teledetección.

ABSTRACT. Maize (*Zea mays* L.) is a globally important crop for food security and livestock production, and its yield strongly influenced by nitrogen (N) availability, a key nutrient involved photosynthesis and grain formation. This study aimed to evaluate the relationship between different vegetation indices (VIs) and N content in hybrid forage maize (variety N83N5), to optimize crop monitoring using remote sensing. The research was conducted at Granja Palestina, Francisco I. Madero, Coahuila, Mexico, using multispectral imagery from the Sentinel-2A and 2B satellites and a Parrot Sequoia sensor mounted on an unmanned aerial vehicle (UAV). A total of 21 VIs were calculated and analyzed using regression models and multivariate analysis. The results showed that spatial resolution and VI selection are critical factors in improving the accuracy of N content estimation models. For Sentinel-2, the best performing model ($R^2 = 0.908$) included CCCI, TCARI/OSAVI RE, TCARI, MSAVI, and MTCI. The Sequoia sensor showed strong performance with simpler model based on GNDVI ($R^2 = 0.814$), SAVI ($R^2 = 0.829$), MSAVI ($R^2 = 0.826$), and NDVI ($R^2 = 0.834$). These findings indicate that selecting appropriate sensors and spectral indices enables the development of accurate methodologies for monitoring N content in maize, supporting precision agriculture applications.

Keywords: Precision agriculture, Predictive models, Parrot Sequoia, Sentinel-2, Remote Sensing.

Como citar: Servín-Prieto AJ, Montemayor-Trejo JA, Trucíos-Caciano R, Estrada-Ávalos J, Orozco-Vidal JA, Yescas-Coronado P (2026) Estimación de nitrógeno foliar en *Zea mays* L. mediante índices de vegetación y sensores multispectrales. Ecosistemas y Recursos Agropecuarios 13(2): e4580. DOI: 10.19136/era.a13n2.4580.

INTRODUCCIÓN

El maíz (*Zea mays* L.) es de los cultivos más importantes en la alimentación mundial. En la actualidad, es el cultivo más extendido a nivel global, con presencia en 170 países. Durante el 2024, el Departamento de Agricultura de Estados Unidos (USDA) reportó que la producción mundial del maíz en el ciclo comercial 2023/24 se ubicó en un máximo histórico de 1 228.1 millones de toneladas. Este volumen representó el 6.1% más respecto a la cosecha del ciclo previo (Gobierno de México 2024). Se estimó una cosechada mundial de 203.2 millones de hectáreas con un rendimiento promedio de 6.04 toneladas por hectárea (FIRA 2024).

En este cultivo, la deficiencia de nitrógeno (N) puede generar pérdidas de producción y disminuir la calidad del producto. Este nutriente es el que las plantas requieren en mayores cantidades, siendo la materia orgánica del suelo una de sus principales fuentes (Farzadfar *et al.* 2021). No obstante, los suelos agrícolas no poseen la suficiente capacidad para cubrir la demanda de N en los cultivos, por lo que se hace preciso suplementarlo mediante la aplicación de fertilizantes (Castellanos *et al.* 2019). La eficacia con la que se aprovecha el N aplicado en los cultivos suele ser baja, generalmente inferior al 50% (Daza-Torres *et al.* 2018). En el maíz, esta eficiencia oscila entre el 35 y el 75% (Morris *et al.* 2018). Cuando este nutriente no es aprovechado adecuadamente, se pierde a través de diversos procesos, como la lixiviación (en forma de nitrato), la volatilización (como amoníaco), la desnitrificación (generando óxidos de nitrógeno, como N₂O y NO₂) y el escurrimiento superficial (Goodkind *et al.* 2023).

La eficiencia en la recuperación del fertilizante nitrogenado está influenciada por diversos factores que interactúan entre sí, como se ha documentado en múltiples estudios. La textura del suelo desempeña un papel fundamental al afectar la retención y movilidad del nitrógeno, siendo los suelos de textura gruesa más propensos a pérdidas por lixiviación (Raun y Johnson 1999, Robertson y Vitousek 2009). Asimismo, los patrones de precipitación, tanto en cantidad como en distribución a lo largo del ciclo vegetativo del cultivo, influyen significativamente en las pérdidas de nitrógeno por lixiviación y volatilización (Cassman *et al.* 2002, Zhang *et al.* 2015). El régimen hídrico también es determinante, ya que los sistemas bajo riego suelen presentar una mayor eficiencia en la recuperación del nitrógeno en comparación con los de temporal, debido a un mejor control de la humedad del suelo (Ladha *et al.* 2005, Fixen *et al.* 2015). Por otra parte, el manejo de la fertilización; incluyendo la dosis, la fuente, el momento y el método de aplicación, es reconocido como un factor clave para optimizar la eficiencia en el uso del nitrógeno (Dobermann 2007, Snyder *et al.* 2008). Finalmente, características propias del cultivo, como la densidad de siembra, la arquitectura radicular y el manejo agronómico, también influyen en la absorción eficiente del nutriente (Fageria y Baligar 2005, Govindasamy *et al.* 2023).

En las últimas décadas, se ha observado que los rendimientos de los cultivos aumentan de manera proporcional al incremento en los niveles de fertilización (Kopittke *et al.* 2019). Sin embargo, en el caso específico de la fertilización nitrogenada, se ha demostrado que elevar las dosis de N reduce su eficiencia de su aprovechamiento (Lu *et al.* 2019), lo que conlleva mayores pérdidas del nutriente, un aumento en la contaminación ambiental (He *et al.* 2022) y costos de producción más elevados debido al mayor uso de fertilizantes (Cassim *et al.* 2022).

En este contexto, la investigación sobre las tecnologías de la información y comunicación (TIC) aplicadas a la agricultura de precisión ha demostrado su valor para el monitoreo de cultivos y la mejora en la gestión de recursos, mediante el uso de sensores remotos y sistemas de análisis de datos que optimizan la producción y la eficiencia agrícola (Díaz *et al.* 2025). Estas tecnologías constituyen un insumo clave para el desarrollo de la agricultura de precisión (Weiss *et al.* 2020). Asimismo, la implementación de sensores, plataformas de análisis de datos y sistemas de monitoreo remoto permite obtener información en tiempo real sobre las necesidades nutricionales de los cultivos, lo que facilita una toma de decisiones más informada y contribuye a la reducción del impacto ambiental de las prácticas agrícolas (Shahab *et al.* 2025). Debido a lo anterior el objetivo de este trabajo fue evaluar la capacidad de las tecnologías emergentes para identificar la deficiencia de N en cultivos de maíz, utilizando datos obtenidos mediante sensores de alta y mediana resolución. Se destaca su aplicabilidad en la agricultura de precisión, así como su contribución potencial a la mejora de la productividad y la sostenibilidad de los cultivos.

MATERIALES Y MÉTODOS

Área de estudio

Granja Palestina se localiza en Francisco I. Madero, Coahuila, México. Es una unidad de producción agrícola-pecuaria que se ubica en 25°46'53" LN y 103°18'28" LO a una altitud de 1 109 msnm. El predio comprende una superficie de 52.6 ha.

Metodología

La Figura 1 muestra el proceso metodológico empleado para estimar el contenido de nitrógeno en el cultivo de maíz mediante el uso de sensores remotos. En primer lugar, se seleccionó este cultivo debido a su relevancia económica para la región y la estrecha relación que existe entre su desarrollo y la disponibilidad de nitrógeno. El proceso continuó con la delimitación del sitio de estudio, considerando factores como el tipo de suelo, las condiciones climáticas y la facilidad de acceso al sitio. Las parcelas elegidas contaron con un tratamiento previamente establecido, lo que permitió realizar un monitoreo continuo durante todo el ciclo de desarrollo del cultivo. Considerando las fechas de siembra definidas por el productor, se elaboró un plan de trabajo para llevar a cabo la recolección de datos tanto en campo como mediante sensores remotos. Por último, se definieron las variables agronómicas y espectrales a medir por su posible influencia en los resultados del estudio.

Durante la etapa de recolección de datos, se llevó a cabo un muestreo destructivo de plantas de maíz para determinar en laboratorio, su contenido de nitrógeno. De manera complementaria, se llevó el registro de las variables agronómicas como la altura de la planta, la medición SPAD y la geolocalización de cada punto de muestreo. En la etapa posterior del proceso, se obtuvieron datos a través de los sensores remotos, para lo que se seleccionó la plataforma de adquisición más adecuada y se documentaron las condiciones de vuelo, incluyendo la hora, la altitud y las condiciones climáticas. A continuación, las imágenes fueron sometidas a correcciones radiométricas y geométricas, y posteriormente se estimaron los índices de vegetación (IV). A partir de estos IV se extrajeron los valores correspondientes a cada sitio de muestreo, los cuales sirvieron

como base para el análisis del contenido de N en el cultivo. Por su parte, para el análisis estadístico se realizó una exploración preliminar de los datos y se aplicó un análisis de componentes principales (ACP) con el objetivo de identificar patrones de variabilidad, reducir la dimensionalidad de las variables espectrales y agronómicas, y así evaluar la correlación entre estas. Por último, se ajustaron los modelos estadísticos para la estimación del contenido de nitrógeno, cuyo desempeño fue evaluado mediante el coeficiente de determinación (R^2) y el error cuadrático medio (RMSE). Con los modelos ajustados, se estimó el contenido de nitrógeno a partir de los índices espectrales, generándose mapas espaciales de la distribución del nutriente, los cuales permitieron interpretar los resultados y evaluar el estado nutricional del cultivo.




Figura 1. Diagrama de flujo de la metodología.

Caracterización del sitio

El sitio produce maíz forrajero híbrido N83N5, la cual es una de las variedades más destacadas para la producción de forraje de alta calidad, especialmente diseñada para la alimentación del ganado (INIFAP 2006). Durante el ciclo Primavera – Verano de 2021 la siembra se realizó el 26 de febrero de 2021. Se sembró a una distancia entre surcos de 76 cm., y se establecieron 8 semillas por metro con una densidad de 102 000 plantas por hectárea. El ciclo vegetativo del cultivo es de 115 días. Durante el manejo del cultivo se realizaron las prácticas agrícolas convencionales, que incluyeron el barbecho, paso de rastra y nivelación. Se aplicó una mezcla de fertilizantes químicos compuesta por 300 kg ha⁻¹ de sulfato de amonio y 100 kg ha⁻¹ de fosfato monoamónico. El programa de riego contempló un aniego realizado durante la segunda semana del mes de febrero, seguido de cuatro riegos de auxilio, efectuados en la tercera semana de los meses de marzo, abril, mayo y junio.

Toma de muestras

La toma de muestras se realizó en un total ocho fechas, con un intervalo de 10 días entre cada muestreo y un total de tres muestras por fecha, considerando la cobertura del satélite Sentinel-2 en el sitio de estudio. Para seleccionar los tres puntos de muestreo, se identificaron las áreas que presentaban valores extremos en el Índice de Vegetación de Diferencia Normalizada (NDVI) (Figura 2). Estos valores se determinaron a partir de una imagen satelital Sentinel-2, generando un mapa de NDVI del sitio y sobre el cual se calculó la desviación estándar para localizar valores bajos y altos. Los valores bajos de NDVI indican estrés vegetal, baja cobertura o deficiencia nutricional, mientras que valores altos están asociados con un mayor vigor vegetativo y un mejor estado del cultivo. En este trabajo, se consideraron como valores bajos extremos aquellos con NDVI menor a 0.3, asociados a suelos desnudos, plantas débiles o con deficiencias, y como valores altos extremos aquellos con NDVI mayores a 0.7, indicativos de una cobertura vegetal densa y saludable. El NDVI es útil para predecir los cambios temporales en la cobertura vegetal sobre las parcelas (Gaitan *et al.* 2021).



Figura 2. Identificación de sitios de muestreo para la fecha 6 de junio de 2021.

Una vez identificados los sitios, se acudió al lugar, para registrar la geolocalización y proceder a la toma de la muestra, para lo cual se identificó un metro cuadrado a partir de la georreferencia y se tomó como representativo al individuo central. Posteriormente, se midieron las variables fisiológicas del cultivo como; altura de la planta, número de hojas, diámetro de la base, etapa fenológica, lectura GreenSeeker, lectura SPAD, temperatura de la planta y temperatura del suelo.

Finalmente se tomó el peso en húmedo de la muestra, para posteriormente llevarla al laboratorio para el análisis de contenido de nitrógeno en planta.

Análisis de la muestra

Una vez recolectadas las muestras se dejaron secar y se trituraron para posteriormente enviarlas al Laboratorio de Suelos del Centro Nacional de Investigación Disciplinaria (CENID) en Relación Agua, Suelo, Planta y Atmósfera (RASPA), donde fueron analizadas, bajo el método de Kjeldahl. El método Kjeldahl es una de las metodologías más utilizadas para determinación de nitrógeno orgánico. En este método la muestra se descompone en medio sulfúrico caliente, en presencia de un agente reductor y catalizador.

Imágenes Sentinel-2A / 2B

Se emplearon imágenes del satélite Sentinel-2A y 2B. Estos sensores fueron lanzados como parte del programa Copernicus de la Agencia Espacial Europea (ESA) (Copernicus Data Space Ecosystem 2023). Proporcionan imágenes multiespectrales con una resolución espacial de 10 m en las bandas visibles e infrarrojas cercanas. Las imágenes fueron descargadas a través del portal Copernicus Open Access Hub. En total se consideraron 21 imágenes (Tabla 1).

Tabla 1. Escenas obtenidas mediante el satélite Sentinel.

No.	DDS	SENSOR	FECHA
1	Aniego	A	21/02/2021
2	6	B	08/03/2021
3	16	A	13/03/2021
4	21	B	18/03/2021
5	26	A	23/03/2021
6	31	B	28/03/2021
7	36	A	02/04/2021
8	41	B	07/04/2021
9	46	A	12/04/2021
10	51	B	17/04/2021
11	66	A	02/05/2021
12	71	B	07/05/2021
13	81	B	17/05/2021
14	86	A	22/05/2021
15	91	B	27/05/2021
16	96	A	01/06/2021
17	101	B	06/06/2021
18	106	A	11/06/2021
19	111	B	16/06/2021
20	116	A	21/06/2021
21	Cosecha	B	26/06/2021

Parrot Sequoia

Para la captura de imágenes de mayor resolución espacial, se utilizó el sensor Parrot Sequoia, que es un sensor multiespectral montado en un Vehículo Aéreo No Tripulado (VANT). Este sensor tiene la capacidad de registrar imágenes en cuatro bandas espectrales: rojo (655 nm), verde (550 nm), azul (475 nm) e infrarrojo cercano (810 nm), con una resolución espacial de 6.8 cm a una altura de vuelo de 70 metros sobre el terreno (Franzini *et al.* 2019).

Las imágenes fueron adquiridas mediante vuelos del VANT realizados, cubriendo parcelas de 10 x 10 m, y se capturaron en intervalos de 5 días durante el ciclo de desarrollo del cultivo y a partir de la fecha de siembra que fue el 22 de marzo de 2021. Se realizaron un total de 19 vuelos los cuales se programaron en un periodo de tiempo de entre las 9:00 y 11:00 h, de la mañana para evitar sobrecalentamiento del equipo y del sensor, así como para evitar la aparición de sombras. Para el diseño del plan de vuelo se utilizó el software eMotion 3® (AgEagle Aerial Systems Inc. 2021). Los parámetros considerados fueron 4 puntos de control, traslapes lateral y frontal del 70 y 60% respectivamente (Figura 3). Se obtuvieron ortomosaicos con una resolución espacial de 18 cm px⁻¹ a una altura de 120 sobre el terreno.




Figura 3. Configuración del plan de vuelo en el software eMotion 3.

Preprocesamiento de las Imágenes

Las imágenes obtenidas tanto de los sensores Sentinel-2A y 2B y del sensor Parrot Sequoia fueron preprocesadas para corregir efectos atmosféricos y eliminar artefactos generados por nubes o sombras. Para las imágenes de Sentinel-2A y 2B se utilizó la herramienta Sen2Cor que consiste en un procesador de corrección atmosférica desarrollado por la ESA para productos del satélite Sentinel-2. Su función es convertir productos de nivel L1C (reflectancia en la parte superior de la atmósfera) en productos L2A (reflectancia a nivel de superficie), aplicando correcciones atmosféricas y topográficas esenciales para el análisis de series temporales (Main-Knorn *et al.* 2017).

Por otro lado, las imágenes obtenidas con el Parrot Sequoia fueron procesadas utilizando el software Pix4D (Pix4D 2020) para mejorar la calidad y precisión geoespacial de los datos. Este sensor permite registrar la radiancia solar durante el vuelo, facilitando la calibración radiométrica de las imágenes y asegurando la consistencia de las mediciones espectrales a lo largo del tiempo (Parrot 2016).

Con el fin de garantizar una mejor precisión geométrica y radiométrica de la información obtenida, el procesamiento de las imágenes se llevó a cabo en tres etapas principales. En la primera se realizó la orientación fotogramétrica mediante el algoritmo *Structure-from-Motion* (SfM), el cual identifica puntos de coincidencia entre imágenes superpuestas y estima la posición relativa de la cámara para reconstruir un modelo tridimensional de la escena. Como parte de este proceso, se incorporaron puntos de control terrestre (GCPs) levantados con receptores GPS lo que permitió mejorar significativamente la exactitud geoespacial de los ortomosaicos generados.

En la segunda etapa se densificó la nube de puntos obtenida durante el proceso de construcción de los ortomosaicos para generar un modelo digital de superficies (MDS) y una malla tridimensional texturizada. Estos productos representan con mayor detalle la topografía del terreno y la estructura de la cobertura vegetal, proporcionando una base confiable para el análisis espacial posterior.

Durante la última etapa se realizó la calibración radiométrica de las bandas espectrales empelando tanto el sensor de irradiancia como el panel de calibración reflectante incluido en el sensor. Este procedimiento permitió convertir los valores digitales (ND) en valores de reflectancia, reduciendo la influencia de las condiciones de iluminación y haciendo posible la comparación entre diferentes fechas de toma. La calibración radiométrica constituye un paso indispensable para obtener estimaciones confiables de los IV, como el NDVI, así como de otras variables biofísicas derivadas de información espectral. (Aasen *et al.* 2018, PIX4D 2020).

Por último, el software generó productos geoespaciales como ortomosaicos multiespectrales corregidos, mapas de reflectancia por banda y mapas de índices de vegetación, todos ellos georreferenciados y compatibles con Sistemas de Información Geográfica (SIG).

Índices de vegetación (IV)

Los IV son métricas espectrales derivadas de combinaciones matemáticas entre distintas bandas de reflectancia captadas por sensores remotos, ya sea desde plataformas satelitales o VANT. Estas herramientas permiten estimar características biofísicas de la vegetación, como la biomasa, el contenido de clorofila, el estado hídrico y la cobertura vegetal, mediante el análisis de la interacción de la radiación electromagnética con los tejidos vegetales (Xue *et al.* 2017). Estos índices son fundamentales para el monitoreo de cultivos, ya que permiten identificar deficiencias nutricionales y otros factores que afectan el crecimiento de las plantas. El índice NDVI es uno de los índices más utilizados en la agricultura de precisión para evaluar la salud del cultivo. La deficiencia de nitrógeno en los cultivos reduce la cantidad de clorofila, lo que afecta la fotosíntesis y, por lo tanto, la salud general de la planta (Jin *et al.* 2015).

Utilizando estos índices, los agricultores pueden identificar áreas dentro del campo con deficiencias de nitrógeno y aplicar fertilizantes de manera precisa y localizada, optimizando los

recursos. Por tanto, se estimaron un total de veintinueve IV a partir de los datos recogidos por los sensores Sentinel-2A / 2B y el sensor Parrot Sequoia.

A partir de las escenas obtenidas, se estimaron los índices de vegetación presentados en la Tabla 2. utilizando el software QGIS® mediante la herramienta de Calculadora Raster. Este proceso permitió calcular y analizar los índices de manera eficiente, facilitando la evaluación de las variables de interés en el estudio.

Tabla 2. Índices de vegetación sensibles a la clorofila.

Índice	Nombre	Autor	Índice	Nombre	Autor
CCCI	Canopy Chlorophyll Content Index	Fitzgerald <i>et al.</i> (2010)	MTVI	Modified Triangular Vegetation Index	Haboudane <i>et al.</i> (2004)
Clgreen	Green Chlorophyll Index	Gitelson <i>et al.</i> (2005)	NDRE	Normalized Difference Red Edge Index	Fitzgerald <i>et al.</i> (2010)
Clred Edge	Red Edge Chlorophyll Index	Gitelson <i>et al.</i> (2005)	NDVI	Normalized Difference Vegetation Index	Rouse <i>et al.</i> (1974)
GNDVI	Green Normalizer Difference Vegetation Index	Gitelson y Merzlyak (1996)	SAVI	Soil Adjusted Vegetation Index	Huete (1988)
LAI	Leaf Area Index	Myneni <i>et al.</i> (2012)	SR	Simple Ratio Index	Melillo <i>et al.</i> (2018)
MCARI	Modified Chlorophyll Absorption Ratio Index	Daughtry <i>et al.</i> (2000)	SR Re	Red Edge-Based Simple Ratio Index	Melillo <i>et al.</i> (2018)
MCARI/OSAVI	Modified Chlorophyll Absorption Ratio Index / Optimized Soil Adjusted Vegetation Index	Haboudane <i>et al.</i> (2002)	TCARI	Transformed Chlorophyll Absorption in Reflectance Index	Haboudane <i>et al.</i> (2002)
MCARI/OSAVI RE	Red Edge - Based Modified Chlorophyll Absorption Ratio Index / Optimized Soil Adjusted Vegetation Index	Wu <i>et al.</i> (2008)	TCARI/OSAVI	Transformed Chlorophyll Absorption in Reflectance Index / Optimized Soil Adjusted Vegetation Index	Haboudane <i>et al.</i> (2002)
MSAVI	Modified Soil Adjusted Vegetation Index	J. Qi <i>et al.</i> (1994)	TCARI/OSAVI RE	Red Edge-Based Transformed Chlorophyll Absorption in Reflectance Index / Optimized Soil Adjusted Vegetation Index	Wu <i>et al.</i> (2008)
MSAVI RE	Red Edge-Based Modified Soil Adjusted Vegetation Index	Jiang Z (2007)	ViOPT	Optimal Vegetation Index	Reyniers <i>et al.</i> (2006)
MTCI	MERIS Terrestrial Chlorophyll Index	Dash and Curran (2004)			

Las imágenes capturadas mediante el sensor Sequoia fueron procesadas en el software Pix4D®, donde se generaron los orto-mosaicos correspondientes. Posteriormente, estos mosaicos se utilizaron para estimar los índices de vegetación con el apoyo de la herramienta Calculadora Raster del software QGIS®. Este flujo de trabajo permitió un análisis preciso y eficiente de los datos espectrales.

Análisis estadístico

La regresión lineal múltiple es un método estadístico que permite modelar la relación entre una variable dependiente y dos o más de una variable independiente, mediante el ajuste de una

ecuación lineal. Este enfoque se utiliza para estimar el efecto individual y conjunto de las variables explicativas sobre la variable de respuesta, asumiendo una relación lineal entre ellas. En este tipo de modelos es importante evaluar la heterocedasticidad, la multicolinealidad y la especificación (Montero-Granados 2016). Para este estudio la variable dependiente es el contenido de nitrógeno N, mientras que las variables independientes son: el número de plantas, número de hojas, diámetro de la base, altura total, etapa fenológica, peso húmedo, peso seco, porcentaje de materia seca, contenido de nitrógeno en la planta, lecturas SPAD-502 y lecturas GreenSeeker, y la lectura de los veintiún índices de vegetación estimados a partir de las imágenes de los sensores.

RESULTADOS

Determinación de Nitrógeno

La Tabla 3 muestra los resultados del trabajo de campo utilizados para evaluar el contenido de nitrógeno (N %) a lo largo del ciclo de desarrollo del cultivo, en distintos puntos georreferenciados del área de estudio y en diferentes fechas de muestreo durante la campaña agrícola 2021. Cada registro corresponde a una muestra puntual tomada en una fecha específica y en una ubicación geográfica definida, lo que permite analizar la variabilidad espacial y temporal del nitrógeno en el cultivo.

Tabla 3. Resultados del análisis de las muestras para determinación de contenido de N.

No.	Fecha	X	Y	Fenología	N (%)	No.	Fecha	X	Y	Fenología	N (%)
1	18/03/2021	668792	2852431	V2	3.93	14	07/05/2021	669305	2852195	V6	2.65
2	18/03/2021	668984	2852335	V1	5.00	15	07/05/2021	668558	2852434	V7	2.35
3	18/03/2021	669314	2852244	V1	4.53	16	17/05/2021	668580	2852429	VT	2.82
4	07/04/2021	668935	2852350	V4	3.12	17	17/05/2021	668910	2852400	VT	2.56
5	07/04/2021	669034	2852324	V4	2.47	18	17/05/2021	668562	2852433	V5	2.85
6	07/04/2021	669014	2852324	V4	3.53	19	27/05/2021	668590	2852394	R2	1.66
7	16/04/2021	669131	2852328	V6	4.28	20	07/06/2021	668695	2852466	PR2	1.78
8	16/04/2021	669174	2852324	V6	3.36	21	16/06/2021	668943	2852390	R2	1.75
9	16/04/2021	669114	2852344	V5	3.36	22	16/06/2021	669127	2852247	R2	1.86
10	16/04/2021	669366	2852511	V4	4.3	23	16/06/2021	669137	2852619	R2	2.18
11	16/04/2021	669335	2852535	V4	3.65	24	25/06/2021	668652	2852397	----	1.77
12	16/04/2021	669295	2852584	V4	3.13	25	25/06/2021	668534	2852474	----	1.73
13	07/05/2021	668574	2852412	V7	2.49	26	25/06/2021	669267	2852210	----	1.93

Los resultados muestran una disminución gradual del contenido de nitrógeno conforme avanza el desarrollo fenológico del maíz. Durante las primeras etapas (V1-V3), se registraron las concentraciones más elevadas, con valores cercanos al 4-5%, mientras que en etapas reproductivas (R2) se observó una reducción considerable. Este comportamiento coincide con la dinámica fisiológica del cultivo, ya que durante el llenado del grano el nitrógeno es movilizado desde los tejidos vegetativos hacia los órganos reproductivos. Por otro lado, se identificaron diferencias en el contenido de nitrógeno entre puntos de muestreo ubicados dentro de una misma parcela, lo que indica la variabilidad espacial asociada a factores como las propiedades del suelo, el manejo

agronómico y la capacidad de absorción de nutrientes por las plantas. Dicha variabilidad respalda el uso de sensores remotos como técnicas de análisis espacial para caracterizar el estado nutrimental del cultivo de manera más precisa.

La información constituyó la base para calibrar y validar los modelos desarrollados en esta investigación, utilizando el contenido de nitrógeno como variable de referencias. Además, permitió evaluar la correlación entre esta variable y la respuesta espectral del cultivo mediante IV y análisis multivariados, como el Análisis de Componentes Principales (ACP), con el propósito de estimar la distribución espacial del nitrógeno en la Granja Palestina.

Imágenes SENTINEL-2A / 2B

La Figura 4 muestra la variabilidad espacial y temporal del NDVI en el sitio de estudio, obtenido mediante el sensor Sentinel-2A y 2B, las fechas representadas abarcan desde la pre-siembra hasta etapas reproductivas avanzadas del cultivo de maíz. En las primeras fechas los valores de NDVI son predominantemente bajos lo que indica escasa cobertura vegetal, asociada a suelo desnudo o a plantas en estados fenológicos muy tempranos. Durante esta etapa, la biomasa aérea es reducida y la actividad fotosintética aún es limitada. A partir de inicios de abril, se observa un incremento gradual del NDVI, reflejado en tonalidades amarillas y verdes claros dentro de las parcelas delimitadas. Este comportamiento coincide con las etapas vegetativas V3-V6 en las que el maíz experimenta un rápido crecimiento foliar, incrementa la cobertura del suelo y mejora su capacidad de absorción de radiación fotosintéticamente activa. En mayo se registran valores de NDVI altos y homogéneos, reflejados en tonalidades verde intenso. Esta respuesta corresponde a las etapas vegetativas avanzadas y cercanas a la floración (V7-VT), cuando el cultivo alcanza su máxima área foliar, presenta una alta concentración de clorofila y desarrolla una intensa actividad fotosintética. Estas condiciones favorecen la implementación de índices espectrales para evaluar el estado nutrimental del cultivo con mayor confiabilidad. En lo que respecta al mes de junio, las imágenes muestran valores de NDVI elevados, aunque en algunas zonas ya se puede observar una ligera estabilización e incluso una disminución puntual. Este comportamiento consiste con el inicio de las etapas reproductivas (R1-R2), cuando el crecimiento vegetativo disminuye y parte del nitrógeno acumulado en las hojas comienza a movilizarse hacia los órganos reproductivos. Como consecuencia, la respuesta del NDVI frente a las variaciones en el estado nutrimental tiende a reducirse, lo que coincide con el comportamiento esperada para esta etapa fenológica del cultivo.

Sensor SEQUOIA

La Figura 5 presenta la evolución espacial y temporal del NDVI obtenido a partir de imágenes capturadas con el sensor multiespectral Parrot Sequoia durante el ciclo de desarrollo del cultivo de maíz, entre marzo y junio de 2021. En las primeras fechas predominan valores bajos de NDVI, asociados principalmente a la presencia de suelo desnudo y a plantas en etapas fenológicas tempranas, cuando la cobertura vegetal y la actividad fotosintética aún son reducidas. A medida que el cultivo avanza en su desarrollo, los valores del NDVI aumentan de manera progresiva, reflejados en la transición hacia tonalidades verdes más intensas. Este comportamiento corresponde con las etapas tempranas (V3-V5), caracterizadas por un rápido crecimiento foliar y un incremento sostenible de la biomasa aérea.




Figura 4. NDVI estimado a partir de las escenas del sensor Sentinel con resolución de 10 m px⁻¹.




Figura 5. NDVI estimado a partir de las escenas del sensor SEQUOIA con resolución de 18 cm px⁻¹.

Como se observa en la figura anterior, hacia finales de abril y durante mayo, el NDVI alcanza sus valores más altos y presenta una distribución espacial relativamente homogénea dentro de la parcela. Esta respuesta corresponde a etapas fenológicas avanzadas y próximas a la floración (V6-VT), cuando el cultivo desarrolla su máxima área foliar, incrementa la concentración de clorofila y

alcanza una elevada capacidad de absorción de radiación fotosintéticamente activa. En estas condiciones la respuesta espectral de la vegetación resulta más sensible a variaciones en el estado nutricional de las plantas. En lo que respecta al mes de junio, el NDVI permanece con valores altos, aunque en algunos sectores se aprecia una ligera estabilización e incluso una disminución puntual. Este comportamiento es consistente con las etapas reproductivas (R1-R2), fase en la que el crecimiento vegetal disminuye y parte de los nutrientes, el N en particular, comienza la movilización hacia los órganos reproductivos, modificando gradualmente la respuesta espectral del cultivo.

Una de las principales ventajas del sensor Parrot Sequoia fue su alta resolución espacial, que permitió identificar con mayor detalle la variabilidad intraparcilaria del índice NDVI y dejar en evidencia las diferencias a nivel de melga de la parcela. Esta capacidad resulta especialmente valiosa en aplicaciones de agricultura de precisión ya que facilita la delimitación de zonas con distinto vigor vegetativo y posible estado nutricional, además de proporcionar datos de alta calidad para la calibración y validación de modelos de estimación del contenido de nitrógeno a escala local.

SENTINEL

La Tabla 4 muestra los resultados del análisis de regresión lineal entre los índices de vegetación seleccionados y el contenido de nitrógeno obtenido de las muestras. Se presentan los cinco índices con mayor coeficiente de correlación. El coeficiente de correlación indica que los índices presentan una relación de moderada a alta con el contenido de nitrógeno. El NDVI exhibe una correlación moderada ($r = 0.698$), mientras que los índices SAVI y MSAVI presentan valores ligeramente superiores ($r = 0.732$ y 0.727 , respectivamente). No obstante, los índices basados en información de clorofila, como CCCI ($r = 0.828$) y ARE ($r = 0.808$), muestran las correlaciones más altas, lo que indica una mayor sensibilidad a las variaciones del estado nutricional del cultivo.

Tabla 4. Índices de vegetación con mejor correlación con el contenido de nitrógeno en planta.

IV	Coef. Corr.	R-cuadrada (%)	R-cuadrado (ajustado para g.l.) (%)	Error estándar del est.	Error absoluto medio	Estadístico Durbin-Watson	Valor-P <0.05	Modelo de Regresión (lineal)
NDVI	0.698	48.768	46.634	0.710	0.587	1.110	0.000	$4.52407 - 3.17844x$
SAVI	0.732	53.625	51.692	0.676	0.560	1.081	0.000	$4.48990 - 4.55305x$
MSAVI	0.727	52.847	52.847	0.681	0.564	1.047	0.000	$4.32184 - 4.38085x$
CCCI	0.828	68.507	68.507	0.557	0.396	1.520	0.000	$5.27508 - 3.99121x$
ARE	0.808	65.329	65.329	0.584	0.426	1.539	0.000	$4.48664 + 16.3491x$

Por su parte, el coeficiente de determinación (R^2) indica que el NDVI explica aproximadamente el 48.8% de la variabilidad del nitrógeno, mientras que SAVI y MSAVI explican alrededor del 53%. En contraste, el índice CCCI presentó el mayor coeficiente de determinación ($R^2 = 68.5\%$), seguido por el índice ARE ($R^2 = 65.3\%$), lo que evidencia un mejor desempeño para estimar el contenido de nitrógeno en el cultivo. Además, los valores de R^2 ajustado fueron muy similares a los coeficientes R^2 en el resto de los modelos, indicando que las ecuaciones mantienen una buena capacidad explicativa sin evidencias de sobreajuste.

En cuanto a la precisión de las estimaciones, los índices CCCI y ARE registraron valores menores tanto en el error estándar del estimador como del error absoluto medio, reflejando una mayor exactitud en las predicciones respecto a NDVI, SAVI y MSAVI. Destaca el comportamiento del CCCI, que obtuvo el menor error absoluto medio (0.396%), evidenciando su mayor capacidad para estimar el contenido de nitrógeno bajo las condiciones evaluadas. Por otra parte, el estadístico de Durbin-Watson presentó valores cercanos a 2 en todos los modelos, lo que sugiere que los resultados o muestran una autocorrelación significativa. De igual manera, los valores de $p < 0.05$ confirman que las relaciones lineales entre los índices de vegetación y el contenido de nitrógeno fueron estadísticamente significativas.

Los modelos de regresión lineal desarrollados constituyen una herramienta confiable para estimar el contenido de nitrógeno a partir de los IV evaluados, siendo el CCCI y en segundo término el ARE, los que ofrecieron el mejor desempeño predictivo. Para la mayoría de los índices (NDVI, SAVI, MSAVI y CCCI), la pendiente es negativa, lo cual es consistente con el comportamiento espectral del cultivo conforme avanza su desarrollo fenológico y se incrementa la biomasa. En el caso del índice ARE, la pendiente positiva refleja su relación directa con la concentración de clorofila y nitrógeno foliar.

El análisis de componentes principales (ACP) seleccionó las variables con mayor incidencia en el modelo del cual se seleccionaron CCCI, TCARI/OSAVI RE, TCARI, MSAVI y MTCI. La Tabla 5 muestra los resultados del modelo de regresión lineal múltiple desarrollado para estimar el contenido de nitrógeno (%) en el cultivo, a partir de estos índices. El modelo obtenido presenta un coeficiente de determinación (R^2) de 90.82%, lo que indica que más del 90% de la variabilidad del contenido de nitrógeno es explicada por la combinación de las variables espectrales incluidas. Asimismo, el valor de R^2 ajustado (88.52%) se mantiene muy próximo al coeficiente de determinación, lo que indica que el modelo conserva una alta capacidad explicativa sin evidencias de sobreajuste, aun cuando incorpora varias variables espectrales.

Tabla 5. Análisis de regresión múltiple.

Variables	R-cuadrada (%)	R-cuadrado (ajustado para g.l.) (%)	Error estándar del est.	Error absoluto medio	Estadístico Durbin-Watson	Valor-P <0.05
a) CCCI	90.819	88.524	0.312	0.197	2.204	0
b) TCARI / OSAVI RE						
c) TCARI						
d) MSAVI						
Modelo de Regresión						
e) MTCI	$8.17213 - (2.86958 * a) - (3.4557 * b) + (12.6971 * c) - (5.89885 * d) + (0.0396524 * e)$					

En relación con la precisión de las estimaciones, el modelo presentó un error estándar del estimador de 0.312 y un error absoluto medio de 0.197, ambos considerablemente inferiores a los obtenidos con los modelos de regresión lineal simple. Estos resultados ponen de manifiesto la ventaja de integrar múltiples índices espectrales, ya que permiten describir de manera más completa la respuesta del cultivo y mejorar la estimación del contenido de nitrógeno. El estadístico de Durbin-Watson (2.204) presentó un valor cercano a 2, lo que sugiere que los residuos del modelo no muestran autocorrelación significativa y que se cumple con uno de los supuestos fundamentales de la regresión lineal. El valor $p < 0.05$ confirma la significancia estadística del modelo en su

conjunto, respaldando su capacidad para estimar el contenido de nitrógeno a partir de la combinación de las variables seleccionadas mediante el ACP.

SEQUOIA

En la Tabla 6 se presentan los resultados del análisis de regresión lineal simple entre distintos IV y el contenido de nitrógeno (%) medido en campo. Los IV evaluados incluyen NDVI, SAVI, NDRE, MSAVI, GNDVI y CL Red, los cuales muestran distintos niveles de sensibilidad al verdor y al contenido de clorofila en el cultivo. El coeficiente de correlación indica que estos índices manifiestan una relación de moderada a alta con el contenido de nitrógeno, donde los valores oscilan entre 0.739 (CL Red) y 0.805 (GNDVI). En particular destacan el GNDVI ($r = 0.805$), SAVI ($r = 0.799$) y MSAVI ($r = 0.795$), esto sugiere una mayor capacidad para captar variaciones relacionadas con el estado nutricional del cultivo. En lo que respecta al coeficiente de determinación (R^2), este varía entre valores de 54.56 y 64.79%. El índice GNDVI muestra el mayor valor de R^2 (64.79%), seguido del SAVI (63.82%) y MSAVI (63.28%) respectivamente, lo que sugiere que estos índices explican una mayor proporción de la variabilidad del nitrógeno foliar. Los valores de R^2 ajustado se muestran ligeramente inferiores, pero cercanos al R^2 , lo que confirma la estabilidad de los modelos y la ausencia de sobreajuste.

Tabla 6. Índices de vegetación con mejor correlación entre el contenido de nitrógeno en planta y el sensor Sequoia.

IV	Coef. Corr.	R-cuadrada (%)	R-cuadrado (ajustado para g.l.) (%)	Error estándar del est.	Error absoluto medio	Estadístico Durbin-Watson	Valor-P <0.05	Modelo de Regresión (lineal)
NDVI	0.792	62.771	60.702	0.601	0.477	0.957	0.000	4.52317 – 3.12797x
SAVI	0.799	63.816	61.806	0.592	0.466	1.113	0.000	4.20196 – 5.04240x
NDRE	0.781	60.922	58.751	0.615	0.485	1.241	0.000	4.04555 – 6.45826x
MSAVI	0.795	63.275	61.234	0.597	0.484	1.125	0.000	4.19403 – 3.35725x
GNDVI	0.805	64.793	62.837	0.584	0.458	0.984	0.000	5.39792 – 4.47107x
CL Red	0.739	54.564	52.040	0.664	0.508	1.257	0.000	3.75244 – 1.81593x

Respecto a los errores de estimación, los índices con mejor desempeño (GNDVI, SAVI y MSAVI) presentan los menores valores de error estándar del estimador (≈ 0.58 - 0.60) y error absoluto medio (≈ 0.46 - 0.48), lo que indica una mayor precisión en la estimación del nitrógeno. Por el contrario, CL Red muestra los errores más altos, reflejando una menor sensibilidad en comparación con los demás índices. Estos resultados evidencian que GNDVI, SAVI y MSAVI son los índices con mejor desempeño para la estimación del contenido de nitrógeno en el cultivo de maíz bajo las condiciones del estudio. No obstante, aunque los modelos simples muestran una capacidad predictiva aceptable, su desempeño es inferior al de los modelos multivariados, lo que refuerza la necesidad de integrar múltiples índices espectrales para mejorar la precisión en aplicaciones de agricultura de precisión.

La Tabla 7 presenta los mismos IV una vez que fueron sometidos a un modelo de ajuste. Los resultados indican que los índices NDVI, SAVI, MSAVI y GNDVI alcanzan coeficientes de correlación muy altos ($r > 0.90$), lo cual evidencia una relación fuerte entre estos IV y el contenido de nitrógeno. El NDVI presenta el mayor coeficiente de correlación ($r = 0.913$) y el valor más alto de R^2 (83.44%), seguido de SAVI (82.94%) y MSAVI (82.60%). Estos valores manifiestan una alta

capacidad explicativa de los modelos ajustados, los cuales superan visiblemente el desempeño observado en los modelos lineales simples. Los valores de R^2 ajustado son cercanos a los de R^2 , lo que confirma la robustez de los modelos y descarta problemas de sobreajuste.

Tabla 7. Índices de vegetación con mejor correlación entre el contenido de nitrógeno en planta y el sensor Sequoia, después de ser ajustados.

IV	Coef. Corr.	R-cuadrada (%)	R-cuadrado (ajustado para g.l.) (%)	Error estándar del est.	Error absoluto medio	Estadístico Durbin-Watson	Valor-P <0.05	Modelo de Regresión (lineal)
NDVI	0.913	83.442	82.523	2.562	2.065	1.478	0.000	$\text{Sqrt}(0.11547 + 3.48107/x)$
SAVI	0.911	82.937	81.989	2.600	1.977	1.449	0.000	$\text{Sqrt}(1.14842 + 1.37845/x)$
NDRE	0.819	67.104	65.276	0.164	0.135	1.012	0.004	$(1.05463 - 0.3177 * \ln(x))^2$
MSAVI	0.909	82.602	81.635	2.626	2.041	1.429	0.000	$\text{Sqrt}(1.59274 + 1.83879/x)$
GNDVI	0.902	81.402	80.369	2.715	2.045	1.304	0.002	$\text{Sqrt}(-6.24837 + 7.81204/x)$
CL Red	0.817	66.773	64.927	0.165	0.137	1.056	0.000	$(1.39821 - 0.264976 * \ln(x))^2$

Asimismo, los errores de estimación (error estándar del estimador y error absoluto medio) se mantienen relativamente bajos en los modelos mejor evaluados, lo que sugiere una mejor precisión predictiva del contenido de nitrógeno. Por su parte, los índices NDRE y CL Red, aunque presentan coeficientes de correlación moderados ($r \approx 0.82$), muestran valores de R^2 inferiores ($\approx 67\%$), lo que indica una menor capacidad explicativa en comparación con los índices basados en el vigor vegetativo sin embargo estos índices continúan siendo estadísticamente significativos ($p < 0.05$) y presentan errores bajos, lo que los hace útiles para aplicaciones específicas relacionadas con la clorofila.

Los resultados confirman que, tras la aplicación de ajustes no lineales, los índices NDVI, SAVI, MSAVI y GNDVI, obtenidos mediante el sensor Parrot Sequoia, son altamente eficientes para la estimación del contenido de nitrógeno en el cultivo de maíz, superando así el desempeño de los modelos lineales simples. Esto destaca el potencial del uso de sensores multispectrales de alta resolución espacial y modelos ajustados para aplicaciones de agricultura de precisión y de manejo nutrimental.

DISCUSIÓN

Determinación de nitrógeno

La tendencia decreciente del contenido de nitrógeno observada a lo largo del ciclo fenológico del maíz coincide con lo reportado en la literatura, en donde se establece que el nitrógeno es progresivamente redistribuido desde los tejidos vegetativos hacia los órganos reproductivos conforme avanza el desarrollo del cultivo (Fageria y Bagilar 2005, Ladha *et al.* 2005). Dicho comportamiento se asocia principalmente con la movilización interna del nitrógeno hacia estructuras como el grano, lo cual explica la disminución de su concentración en hojas durante etapas reproductivas. En esta investigación los valores más altos se registraron en etapas tempranas (V1-V3) y su disminuyó hacia las etapas reproductivas (R2) lo que refleja claramente este proceso.

De esta manera, la variabilidad espacial observada entre los puntos de muestreo cercanos muestra la heterogeneidad intraparcelar del sistema agrícola, lo que ha sido documentado como resultado de diferencias en características como propiedades del suelo, disponibilidad hídrica y prácticas de manejo agronómico (Cassman *et al.* 2002). Esta variabilidad destaca la importancia de utilizar herramientas que permitan el monitoreo a una alta escala espacial, ya que los métodos tradicionales de muestreo puntual no logran capturar completamente dicha dinámica.

En este contexto, los resultados respaldan la necesidad de implementar técnicas de agricultura de precisión basadas en sensores remotos de media o alta resolución, las cuales permitan una evaluación continua y no destructiva del estado nutricional del cultivo. Algunos autores han señalado que el uso de IV obtenidos a partir de imágenes multiespectrales representa una alternativa eficiente para estimar el contenido de nitrógeno en cultivos especialmente en sistemas de alta variabilidad espacial (Zhang *et al.* 2015).

Imágenes SENTINEL-2A / 2B

El comportamiento del índice NDVI observado en los resultados, caracterizado por valores bajos en las etapas iniciales, su incremento durante el desarrollo fenológico y la estabilización en etapas reproductivas coincide con la dinámica espectral reportada para cultivos de maíz (Zhang *et al.* 2015; Salvador-Castillo *et al.* 2022). En etapas tempranas, los valores bajos de NDVI muestran una limitada cobertura vegetal y la baja actividad fotosintética, mientras que el aumento progresivo está asociado al incremento en la biomasa foliar y el contenido de clorofila. La estabilización del NDVI en etapas avanzadas del cultivo se atribuye al fenómeno de saturación del índice en condiciones de alta biomasa, lo que limita su sensibilidad para detectar cambios en el estado nutrimental (Gitelson 2004, Zhang *et al.* 2015). Dicho comportamiento explica por qué su capacidad para estimar nitrógeno puede disminuir en etapas cercanas a la floración del cultivo, aun cuando es el índice más utilizado. De esta forma, factores como la resolución espacial y los efectos atmosféricos tiene influencia en la calidad de los datos obtenidos a partir de los sensores remotos, lo cual ha sido señalado como una de las principales limitantes en estudios basados en la implementación de Sentinel-2 (Salvador-Castillo *et al.* 2022). Sin embargo, por su alta resolución temporal y espacial lo hacen una excelente herramienta en el monitoreo del cultivo a una escala regional.

Sensor SEQUOIA

Los resultados obtenidos a partir del uso del sensor Parrot Sequoia presentan una mayor capacidad para detectar variabilidad espacial a nivel intraparcelar, esto se atribuye a su alta resolución espacial comparado con los datos tomados mediante satélite. Esta conducta se ha documentado en otros estudios, en donde se destaca que los sensores instalados en UAV permiten obtener información detallada del cultivo, lo que mejora la identificación de patrones de variabilidad asociados al vigor vegetativo y al estado nutricional (Sehgal *et al.* 2024, Hunt *et al.* 2010).

El progreso del índice NDVI observado con este sensor sigue una tendencia similar a la registrada con Sentinel-2; sin embargo, presenta una mayor definición espacial que permite identificar diferencias dentro de la parcela, como las variaciones entre melgas. Este nivel de detalle es esencial en aplicaciones de agricultura de precisión, en donde el objetivo es optimizar el manejo del cultivo

a una escala local. Al mismo tiempo, la alta resolución espacial contribuye a reducir los efectos de la mezcla espectral presentes en los datos satelitales, lo cual permite mejorar la sensibilidad del índice en la detección de cambios en el estado del cultivo (Gitelson *et al.* 2005). Esto refuerza el alto potencial del uso de UAV's como complemento a la información satelital en estudios de monitoreo nutrimental.

SENTINEL

En cuanto a Sentinel-2, los resultados confirman que los IV derivados de imágenes tomadas por este satélite, constituyen a herramientas robustas para la estimación del contenido de nitrógeno en el cultivo de maíz. Los valores de coeficiente de determinación alcanzados (R^2 hasta 0.90 en modelos multivariados) muestran una alta capacidad predictiva cuando se integran múltiples variables espectrales, lo cual coincide con lo reportado en otros estudios que han documentado el potencial de estos sensores para el monitoreo nutrimental (Sharifi 2020, Salvador-Castillo *et al.* 2022).

En el análisis de modelos individuales, el índice NDVI presentó una mayor capacidad explicativa ($R^2 = 0.82$) en comparación con el NDRE ($R^2 = 0.67$), lo cual indica que, bajo las condiciones de la presente investigación, el NDVI mantiene una mayor sensibilidad para explicar la variabilidad del nitrógeno. Sin embargo, esta diferencia puede estar influenciada por factores como la estructura del dosel, la etapa fenológica y la resolución espacial del sensor utilizado. Estudios previos han señalado que, aunque el NDVI es ampliamente implementado, los índices basados en el borde del rojo logran ofrecer ventajas en la estimación del contenido de nitrógeno, particularmente en condiciones de alta biomasa (Sharifi 2020, Wijayanto *et al.* 2023).

De igual forma, los valores de R^2 obtenidos son consistentes con los reportados en la literatura para imágenes Sentinel-2, donde se han observado correlaciones de moderadas a altas entre índices de vegetación y variables biofísicas del cultivo. No obstante, algunos autores han atribuido las variaciones en estos valores a factores externos como son los efectos atmosféricos, la resolución espacial y las condiciones de adquisición de las imágenes (Salvador-Castillo *et al.* 2022). Lo que sugiere que la precisión de los modelos puede verse limitada cuando se utilizan datos satelitales sin correcciones adicionales o en condiciones ambientales variables.

Por otra parte, el alto desempeño del modelo de regresión lineal múltiple obtenido en este estudio ($R^2 = 0.908$) confirma que la integración de múltiples IV mejora significativamente la capacidad predictiva en comparación con modelos basados en un solo índice. Este resultado es similar a los obtenidos en investigaciones previas donde se ha demostrado que la combinación de variables espectrales permite capturar de manera más eficiente la complejidad del estado fisiológico del cultivo (Cano-Mejía *et al.* 2023, Yao *et al.* 2010). A diferencia de estudios donde se emplea un mayor número de índices con resultados moderados, en este caso se logró un alto nivel de ajuste con un conjunto reducido de variables (CCCI, TCARI, TCARI/OSAVI RE, MSAVI y MTCI), lo que indica que la selección adecuada de índices es más determinante que la cantidad de variables incluidas.

En este sentido, los IV que incorporan información del borde del rojo (Red Edge) y del infrarrojo cercano (NIR) mostraron un mejor desempeño al integrarse en el modelo multivariado, lo cual respalda lo reportado por otros autores que destacan la sensibilidad de estas bandas para detectar

variaciones en la concentración de clorofila y nitrógeno en el dosel vegetal (Inoue *et al.* 2012; Hunt Jr. *et al.* 2011). De manera particular, los índices CCCI y TCARI/OSAVI han sido reconocidos por su capacidad para reducir efectos de saturación y mejorar la estimación del estado nutrimental del cultivo (Chen *et al.* 2010). Por último, los resultados conseguidos superan los valores reportados en estudios previos donde analizaron cultivos como el trigo, y donde se obtuvieron coeficientes de determinación menores utilizando enfoques similares con datos Sentinel-2 (Zhao *et al.* 2019), lo cual se atribuye a diferencias en condiciones de cultivo, manejo agronómico y selección de índices.

SEQUOIA

Los modelos de regresión generados a partir del sensor Parrot Sequoia mostraron un desempeño superior en comparación con los modelos lineales simples, particularmente después de la aplicación de ajustes no lineales. Los altos coeficientes de correlación ($r > 0.90$) y valores de R^2 superiores al 80% evidencian una fuerte relación entre los índices de vegetación y el contenido de nitrógeno, lo cual coincide con lo reportado en estudios donde se ha demostrado que los sensores de alta resolución espacial mejoran la precisión en la estimación de variables biofísicas del cultivo (Zhao *et al.* 2019, Yao *et al.* 2010).

Los índices GNDVI, SAVI, MSAVI y NDVI destacaron por su alta capacidad predictiva, lo cual ha sido previamente documentado debido a su sensibilidad a la concentración de clorofila y a la estructura del dosel vegetal (Gitelson *et al.* 2005, Wijayanto *et al.* 2023). En particular, el GNDVI ha sido señalado como un índice eficiente en condiciones de alta biomasa, ya que reduce los efectos de saturación observados en el NDVI. La mejora significativa en los modelos ajustados sugiere que las relaciones entre las variables espectrales y el contenido de nitrógeno no son estrictamente lineales, lo cual ha sido ampliamente discutido en la literatura. Estudios previos recomiendan el uso de transformaciones matemáticas o modelos no lineales para capturar de manera más precisa la complejidad de estas relaciones (Yao *et al.* 2010, Zhao *et al.* 2019). En conjunto, estos resultados confirman que el uso de sensores UAV, combinado con modelos ajustados, representa una herramienta altamente eficiente para la estimación del contenido de nitrógeno en cultivos, superando las limitaciones de los modelos lineales simples y proporcionando información clave para la toma de decisiones en agricultura de precisión.

CONCLUSIONES

La resolución espacial de las imágenes utilizadas desempeña un papel fundamental en la precisión de los modelos de estimación del contenido de nitrógeno en cultivos. Esta resolución no está determinada únicamente por las especificaciones técnicas del sensor remoto, sino también por las condiciones de adquisición y altura de vuelo. El sensor Parrot Sequoia, pese a tener una resolución fija, registra imágenes con diferentes tamaños de píxel sobre el terreno dependiendo de la altitud del vuelo, lo que afecta directamente la capacidad para detectar variabilidad espacial fina dentro del cultivo. En este estudio, el sensor Sentinel-2, con resolución espacial media, requirió un modelo de regresión múltiple que integró cinco índices espectrales (CCCI, TCARI/OSAVI RE, TCARI, MSAVI y MTCI), alcanzando un coeficiente de determinación ($R^2 = 0.908$), lo cual demuestra que la combinación de varios índices mejora la capacidad predictiva del modelo. En contraste, el sensor

Parrot Sequoia, operado a 120 msnm de altura, logró buenos resultados con un modelo más simple basado en los índices GNDVI ($R^2 = 0.814$), SAVI ($R^2 = 0.829$), MSAVI ($R^2 = 0.826$) y NDVI ($R^2 = 0.834$), lo que resalta la efectividad de estos índices bajo condiciones de alta resolución espacial. Estos resultados evidencian que la resolución espacial efectiva de las imágenes y la selección adecuada de índices espectrales son factores determinantes en la precisión de los modelos, y que su elección debe adaptarse a las características específicas del cultivo, del entorno y de los objetivos del monitoreo.

AGRADECIMIENTOS

Al Tecnológico Nacional de México, Instituto Tecnológico Superior de Lerdo, Instituto Tecnológico de Torreón e Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias Campo Experimental CENID RASPA por las facilidades brindadas para la realización de esta investigación.

DECLARACIÓN SOBRE USO DE HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL GENERATIVA

En la investigación y/o preparación de este manuscrito, los autores utilizaron SciSpace® y Gemini® con el objetivo de corrección del estilo de redacción. La revisión, verificación, edición e interpretación de lo aportado por estas herramientas fue realizada por los autores, quienes asumen la total responsabilidad por el contenido publicado.

CONFLICTO DE INTERÉS

Los autores declaran que no tienen intereses en competencia.

LITERATURA CITADA

- Aasen H, Burkart A, Bolten A, Bareth G (2018) Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. ISPRS Journal of Photogrammetry and Remote Sensing 145: 245-259. <http://doi.org/10.1016/j.isprsjprs.2015.08.002>
- AgEagle Aerial Systems Inc. (2021) eMotion 3 [Software]. SenseFly. Consultado el 10 de abril de 2026. <https://www.sensefly.com/drone-software/emotion/>
- Cano-Mejía B, Valdez-Cepeda RD, López-Santos A (2023) Estimación de cosecha de maíz forrajero (*Zea mays* L.) mediante índices espectrales derivados de LANDSAT-8 y SENTINEL-2. Terra Latinoamericana 41:e1696. <https://doi.org/10.28940/terra.v41i0.1696>
- Castellanos RJZ, Etchevers BJD, Peña DM, García HS, Ortiz MI, Arango GA, Venegas VC (2019) ¿Cómo crece y se nutre una planta de maíz? Fertilab. Querétaro, México. 136p

- Cassim BMAR, Besen MR, Kachinski WD, Macon CR, Almeida Junior JHV, Sakurada R, Batista MA (2022) Nitrogen fertilizer technologies for corn in two yield environments in South Brazil. *Plants* 11:1890. <https://doi.org/10.3390/plants11141890>
- Cassman KG, Dobermann A, Walters DT (2002) Agroecosystems, nitrogen-use efficiency, and nitrogen management. *Ambio* 31(2): 132-140. <https://doi.org/10.1579/0044-7447-31.2.132>
- Chen P, Haboudane D, Tremblay N, Wang J, Vigneault P, Li B (2010) New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. *Remote Sensing of Environment* 114: 1987-1997. <https://doi.org/10.1016/j.rse.2010.04.006>
- Copernicus Data Space Ecosystem (2023) Sentinel-2 data collection [Data set]. Consultado el 10 de abril de 2026. <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>
- Daughtry CST, Walthall CL, Kim MS, Brown de Colstoun E, McMurtrey JE (2000) Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment* 74: 229-239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- Dash J, Curran PJ (2004) The MERIS terrestrial chlorophyll index. *International Journal of Remote Sensing* 25: 5403-5413. <https://doi.org/10.1080/0143116042000274015>
- Daza-Torres MC, Ladino-Tabarquino GS, Urrutia-Cobo N (2018) Beneficios agronómicos y ambientales de fertilizantes nitrogenados en *Ocimum basilicum* L. *DYNA* 85(206): 294-303. <https://doi.org/10.15446/dyna.v85n206.69103>
- Díaz J, Quiñonez Y, De-la-Hoz-Franco E, Butt-Aziz S, Mercado T, Salcedo D (2025) Information and communication technologies used in precision agriculture: A systematic review. *AgriEngineering* 7(6): 167. <https://doi.org/10.3390/agriengineering7060167>
- Dobermann A (2007) Nutrient use efficiency: Measurement and management (28 pp.). International Fertilizer Industry Association, París, France.
- European Space Agency (2015) Sentinel-2 user handbook. Issue 1, Revisión 2. Copernicus Programme. Consultado el 10 de abril de 2026. https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook
- Fageria NK, Baligar VC (2005) Enhancing nitrogen use efficiency in crop plants. *Advances in Agronomy* 88: 97-185. [https://doi.org/10.1016/S0065-2113\(05\)88004-6](https://doi.org/10.1016/S0065-2113(05)88004-6)
- Farzadfar S, Knight JD, Congreves KA (2021) Soil organic nitrogen: An overlooked contribution to crop nutrition. *Plant and Soil* 462: 7-23. <https://doi.org/10.1007/s11104-021-04860-w>
- Fitzgerald G, Rodríguez D, O'Leary G (2010) Measuring canopy nitrogen using the canopy chlorophyll content index (CCCI). *Field Crops Research* 116: 318-324. <https://doi.org/10.1016/j.fcr.2010.01.010>
- Fixen PE, Brentrup F, Bruulsema TW, Garcia F, Norton R, Zingore S (2015) Nutrient use efficiency: Measurement and trends. International Fertilizer Industry Association (IFA). París, France. 30p.
- Franzini M, Ronchetti G, Sona G, Casella V (2019) Geometric and radiometric consistency of Parrot Sequoia multispectral imagery for precision agriculture applications. *Applied Sciences* 9(24): 5314. <https://doi.org/10.3390/app9245314>
- Gaitán J, Ciano N, Oliva G, Bran D, Butti L, Cariac G, Caruso C, Opazo W, Ferrante D, Echevarria D, Buono G, Fantozzi A, Guirado E, Maestre F (2021) Variación temporal del NDVI en tierras secas. *Ecosistemas* 30: 2229. <https://doi.org/10.7818/ECOS.2229>
- Gitelson AA, Merzlyak MN (1996) Reflectance spectra for chlorophyll estimation. *Journal of Plant Physiology* 148: 494-500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
- Gitelson AA, Viña A, Ciganda V, Rundquist DC, Arkebauer TJ (2005) Remote estimation of canopy chlorophyll. *Geophysical Research Letters* 32. <https://doi.org/10.1029/2005GL022688>
- Goodkind AL, Thakrar SK, Polasky S, Hill JD, Tilman D (2023) Managing nitrogen in maize production. *PNAS Nexus* 2. <https://doi.org/10.1093/pnasnexus/pgad319>

- Govindasamy P, Muthusamy SK, Bagavathiannan M, Mowrer J, Jagannadham PTK, Maity A, Tiwari G (2023) Nitrogen use efficiency under climate change. *Frontiers in Plant Science* 14: 1121073. <https://doi.org/10.3389/fpls.2023.1121073>
- Haboudane D (2004) Hyperspectral vegetation indices for precision agriculture. *Remote Sensing of Environment* 90: 337-352.
- Haboudane D, Miller JR, Tremblay N, Zarco-Tejada PJ, Dextraze L (2002) Narrow-band vegetation indices. *Remote Sensing of Environment* 81: 416-426.
- Huete A (1988) Soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25: 295-309.
- Hunt ER Jr, Daughtry CST, Eitel JUH, Long DS (2011) Leaf chlorophyll estimation using visible bands. *Agronomy Journal* 103: 1090-1099.
- Inoue Y, Sakaiya E, Zhu Y, Takahashi W (2012) Mapping canopy nitrogen content. *Remote Sensing of Environment* 126: 210-221.
- Jiang Z (2007) Interpretation of MSAVI. *Journal of Applied Remote Sensing* 1: 013503. <https://doi.org/10.1117/1.2709705>
- Jin X, Li Y, Wang Z (2015) Monitoring nitrogen deficiency using NDVI and GNDVI. *Precision Agriculture* 16: 842-853.
- Kopittke PM, Menzies NW, Wang P, McKenna BA, Lombi E (2019) Soil and agricultural intensification. *Environment International* 132: 105078. <https://doi.org/https://doi.org/10.1016/j.envint.2019.105078>
- Ladha JK, Pathak H, Krupnik TJ, Six J, van Kessel C (2005) Fertilizer nitrogen efficiency. *Advances in Agronomy* 87: 85-156.
- Lu C, Zhang J, Cao P, Hatfield JL (2019) Nitrogen use efficiency trends. *Earth's Future* 7: 939-952.
- Main-Knorn M, Pflug B, Louis J, Debaecker V, Müller-Wilm U, Gascon F (2017) Sen2Cor atmospheric correction. *SPIE Proceedings*. <https://doi.org/10.1117/12.2278218>
- Melillos G, Diofantos G, Hadjimitsis DG (2018) Using simple ratio (SR) vegetation index to detect deep man-made infrastructures in Cyprus. *Proceedings of SPIE* 11418: 114180E. <https://doi.org/10.1117/12.2557893>
- Montero Granados R (2016) Modelos de regresión lineal múltiple (Documento de Trabajo de Economía Aplicada). Departamento de Economía Aplicada, Universidad de Granada. Granada, España. 61 pp.
- Morris TF, Murrell TS, Beegle DB, Camberato JJ, Ferguson RB, Grove J, Yang H (2018) Nitrogen recommendations for corn. *Agronomy Journal* 110: 1-37.
- Myneni RB, Hoffman S, Knyazikhin Y, Privette JL, Glassy J, Tian Y *et al.* (2002) Global products of vegetation leaf area and fraction absorbed PAR from MODIS data. *Remote Sensing of Environment* 83(1-2): 214-231.
- Núñez HG, González CF, Faz CR, Figueroa VU, Nava CU, Peña RA, Reta SD (2006). Tecnología de producción de maíz forrajero de alto rendimiento (Folleto Técnico Núm. 13). Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias.
- Parrot (2015) Sequoia multispectral sensor user guide (User Guide, Version 1.0 76 pp.). Parrot SA. <https://www.parrot.com/us/enterprise/sequoia>
- Pix4D (2020) Pix4Dmapper user manual. Pix4D SA. Lausanne, Switzerland. Consultado el 10 de abril de 2026. https://data.pix4d.com/misc/manual_pdf/manual_4_1.pdf
- Qi J, Chehbouni A, Huete A, Kerr Y, Sorooshian S (1994) Modified soil-adjusted vegetation index (MSAVI). *Remote Sensing of Environment* 48: 119-126.
- Raun WR, Johnson GV (1999) Improving nitrogen use efficiency. *Agronomy Journal* 91: 357-363.
- Reyniers M, Walvoort DJJ, De Baardemaaker J (2006) A linear model to predict nitrogen content in winter wheat using a multispectral radiometer. *International Journal of Remote Sensing* 27: 4159-4179.
- Robertson GP, Vitousek PM (2009) Nitrogen in agriculture. *Annual Review of Environment and Resources* 34: 97-125.

- Rouse JW, Haas RH, Schell JA, Deering DW (1974) Monitoring vegetation systems with ERTS. Proceedings of the Third Earth Resources Technology Satellite-1 Symposium Vol. 1, NASA. Texas A&M University. pp. 309-317
- Salvador-Castillo JM, Bolaños-González MA, Palacios-Vélez E, Palacios-Sánchez LA, López-Pérez A, Muñoz-Pérez JM (2021) Estimación de nitrógeno en maíz mediante sensores remotos. *Terra Latinoamericana* 39: e841. <https://doi.org/10.28940/terra.v39i0.899>
- Sehgal V, Bag K, Dhakar R, Shrivastava M (2024) Digital sensing of crop nitrogen content for site-specific nitrogen management: A review. *Indian Journal Fertilisers*, 20(11), 1068-1081.
- Shahab H, Naeem M, Iqbal M, Aqeel M, Ullah SS (2025) IoT-driven smart agricultural technology for real-time soil and crop optimization. *Smart Agricultural Technology* 100847. <https://doi.org/10.1016/j.atech.2025.100847>
- Sharifi A (2020) Using Sentinel-2 data to predict nitrogen uptake in maize. *IEEE Journal of Selected Topics* 13: 2656-2662.
- Weiss M, Jacob F, Duveiller G (2020) Remote sensing for agriculture: A meta-review. *Remote Sensing of Environment* 236: 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Wijayanto B, Sumarmi S, Utomo DH, Handoyo B, Aliman M (2023) Problem-based learning using e-module: Effects on higher-order thinking and learning interest in geography. *Journal of Technology and Science Education* 13:613. <https://doi.org/10.3926/jotse.1965>
- Wijayanto Y, Safitri M, Purnamasari I, Budiman S, Saputra T, Regar A, Ristiyana S (2024) Estimating chlorophyll, nitrogen, and yield in rice using Sentinel-2 vegetation indices. *Indonesian Journal of Geography* 56(3). <https://doi.org/10.22146/ijg.87159>
- Wu C, Niu Z, Tang Q, Huang W (2008) Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and Forest Meteorology* 148(8-9): 1230-1241. <https://doi.org/10.1016/j.agrformet.2008.03.005>
- Xue J, Su B (2017) Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors* 1353691. <https://doi.org/10.1155/2017/1353691>
- Yao X, Zhu Y, Tian Y, Feng W, Cao W (2010) Hyperspectral estimation of nitrogen in wheat. *International Journal of Applied Earth Observation and Geoinformation* 12: 89-100.
- Zhang X, Davidson EA, Mauzerall DL, Searchinger TD, Dumas P, Shen Y (2015) Managing nitrogen for sustainable development. *Nature* 528: 51-59.
- Zhao H, Song X, Yang G, Li Z, Zhang D, Feng H (2019) Monitoring nitrogen in wheat using Sentinel-2. *Data. Remote Sensing* 11(14): 1724. <https://doi.org/10.1007/s44279-024-00069-4>