

Identificación de índices de vegetación relacionados con componentes de rendimiento de frijol común (*Phaseolus vulgaris* L.) mediante el uso de sensores multiespectrales

Identification of vegetation indices related to yield components of common bean (*Phaseolus vulgaris* L.) using multispectral sensors

Guillermo Vargas-Hernández¹, Eddison José Araya-Morales²,
Juan Carlos Hernández-Fonseca³, Ignacio Mora-Cordero⁴

Fecha de recepción: 8 de diciembre, 2025
Fecha de aprobación: 17 de abril, 2026

Vargas-Hernández, G; Araya-Morales, E.J; Hernández-Fonseca, J.C; Mora-Cordero, I. Identificación de índices de vegetación relacionados con componentes de rendimiento de frijol común (*Phaseolus vulgaris* L.) Mediante el uso de sensores multiespectrales . *Tecnología en Marcha*. Vol. 39 N° 4. Octubre-Diciembre, 2026. Pág. 3-19.

 <https://doi.org/10.18845/tm.v39i4.8378>



- 1 Estación Experimental Fabio Baudrit Moreno, Universidad de Costa Rica, Alajuela, Costa Rica.
 guillermo.vargas@ucr.ac.cr
 <https://orcid.org/0000-0003-1410-3898>
- 2 Instituto Nacional de Innovación y Transferencia de Tecnología Agropecuaria, Alajuela, Costa Rica.
 earayam@inta.go.cr
 <https://orcid.org/0009-0001-0550-414X>
- 3 Instituto Nacional de Innovación y Transferencia de Tecnología Agropecuaria, Alajuela, Costa Rica.
 jchernandez@inta.go.cr
 <https://orcid.org/0000-0002-1915-3213>
- 4 Universidad de Costa Rica, Alajuela, Costa Rica.
 ignacio.moracordero@ucr.ac.cr
 <https://orcid.org/0009-0007-0925-0099>

Palabras clave

Agricultura de precisión; fenotipado remoto; teledetección; modelos predictivos; drones; UAV.

Resumen

La producción de frijol en Costa Rica solo abastece un 20 % del consumo interno, lo que obliga a importar la restante demanda; esta situación justifica la necesidad de conocer con anticipación la capacidad productiva real de los agricultores locales para mejorar la planificación, el manejo agronómico y la regulación de las importaciones. Por ello, el objetivo de este estudio fue evaluar la utilización de datos multiespectrales e índices de vegetación para analizar su relación con los componentes de rendimiento en variedades de frijol cultivadas en distintas zonas productoras de Costa Rica, con el fin de identificar los índices de vegetación y el componente de rendimiento con mayor asociación espectral.

La investigación se desarrolló en tres sitios ubicados en Alajuela, Costa Rica. Mediante un sensor multiespectral aerotransportado se capturaron datos de reflectancia durante la etapa fenológica R5. Posteriormente, se cuantificaron los componentes de rendimiento por cada metro lineal de cultivo, tales como: peso de 100 granos, el número de vainas por metro, número de plantas, número de granos y peso total de granos. El número de vainas obtuvo la mayor asociación con las variables espectrales, por lo que fue identificado como el componente de rendimiento con mayor potencial para el análisis mediante teledetección. Los índices SR (Simple Ratio) y GCI (Green Chlorophyll Index) presentaron correlaciones superiores a 0,7 con esta variable, identificándose como los índices de vegetación con mayor asociación espectral durante la etapa R5 del cultivo.

Keywords

Precision agriculture; remote phenotyping; remote sensing; predictive models; drones; UAV.

Abstract

Bean production in Costa Rica supplies only 20 % of domestic consumption, requiring the importation of the remaining amount; this situation highlights the need to know in advance the actual productive capacity of local farmers to improve planning, agronomic management, and import regulation. Therefore, the objective of this study was to evaluate the use of multispectral data and vegetation indices to analyze their relationship with yield components in bean varieties cultivated in different production areas of Costa Rica and to identify the yield component with the greatest spectral association.

The research was conducted at three sites located in Alajuela, Costa Rica. Multispectral reflectance data were collected during the R5 phenological stage using an airborne multispectral sensor. Subsequently, yield components were quantified per meter of crop row, including 100-grain weight, number of pods per meter, number of plants, number of grains, and total grain weight. The number of pods showed the highest association with spectral variables and was therefore identified as the yield component with the greatest potential for analysis through remote sensing. The SR (Simple Ratio) and GCI (Green Chlorophyll Index) indices showed correlations greater than 0.7 with this variable, being identified as the vegetation indices with the highest spectral association during the R5 stage of the crop.

Introducción

El frijol común (*Phaseolus vulgaris* L.) es una leguminosa de la familia Fabaceae y tribu Phaseoleae, es utilizada ampliamente como sustento de poblaciones con bajos recursos en países en vías de desarrollo [1], como Costa Rica. El país no es autosuficiente en la producción de este cultivo, cuya área sembrada ha disminuido en los últimos años y solo abastece alrededor de un 20% del consumo [2]. En Latinoamérica, se ha fortalecido el desarrollo de este cultivo en varias líneas de investigación que van desde el mejoramiento genético hasta la teledetección, con el objetivo de mejorar la eficiencia en la producción de este grano [3], [4], [5] especially under increasingly challenging climate conditions. Data synthesis can aggregate data from individual trials to produce information that supports decision making in plant breeding programs, extension services, and of farmers. Data from on-farm trials using the novel approach of triadic comparison of technologies (tricot).

Es necesario que el productor nacional pueda contar con herramientas tecnológicas como la predicción de cosecha para mejorar los sistemas agrícolas y optimizar los procesos en la cadena de producción de alimentos [6], aumentando su competitividad con respecto a las empresas que importan el grano de otras latitudes para abastecer la demanda de la población nacional [7], [8].

La teledetección aplicada a la agricultura de precisión ha demostrado ser una herramienta tecnológica muy valiosa para el manejo de los sistemas de producción agrícola [9], donde se destaca el aporte de los índices de vegetación para el aumento en la precisión y disminución del tiempo de respuesta en el monitoreo de los cultivos [10]. La utilización de vehículos aéreos no tripulados y de sensores para la obtención de imágenes multiespectrales de los cultivos, representa una alternativa no destructiva valiosa para obtener información relacionada al estado fenológico de las plantas y estimar su rendimiento [11] sensors, and data processing while also introducing recent technological developments. Recently developed software and sensors greatly enhance the accessibility of UAV-based phenotyping, and a summary of recent research (publications 2019–2024. De acuerdo con Li et al. [12] las principales técnicas utilizadas incluyen el procesamiento de imágenes dentro del espectro visible rojo-verde-azul (RGB), espectroscopía de imágenes, imágenes 3D, térmicas y de fluorescencia.

Los índices de vegetación han sido ampliamente aprovechados para dar seguimiento al estado fenológico, vigor y rendimiento de los cultivos, así como el efecto que tiene el estrés biótico y abiótico sobre su desarrollo [11], [13]. Estos se han utilizado para estudiar las variables relacionadas con el desarrollo de los granos básicos debido a su importancia alimenticia [13]. En Brasil, Boechat et al. [14] estudiaron la huella espectral obtenida en plantas de frijol afectadas por moho blanco provocado por *Sclerotini sclerotiorum* mediante tres índices de vegetación: índice de vegetación de diferencia normalizada (NDVI), índice de vegetación ajustado al suelo (SAVI) e índice de vegetación de diferencia normalizada verde (GNDVI). Y determinaron que únicamente el NDVI obtenido 71 días después de germinación tuvo buena correlación con el deterioro de las hojas provocado por la enfermedad.

En una investigación conducida en Argentina, Girón y Pagani [15] evaluaron el uso del índice de vegetación de diferencia normalizada (NDVI) como criterio para la delimitación de zonas de manejo en función de diferentes dosis de nitrógeno y de la variación espacial. Los investigadores concluyeron que este índice no presentó la sensibilidad necesaria para discriminar adecuadamente la variabilidad espacial de la producción como respuesta a la fertilización nitrogenada.

Trapp et al. [16] evaluaron el rendimiento de variedades de frijol altamente susceptibles y tolerantes a la sequía determinando el NDVI en dos etapas de llenado de la vaina (media y tardía). Se determinó que este índice mostró buena correlación con el rendimiento (kg. ha^{-1}) y

llenado de vainas para las variedades tolerantes bajo estrés hídrico, y se obtuvo una correlación significativa con ambas variables para las variedades susceptibles tanto en condiciones normales como de estrés hídrico.

Sankaran et al. [16] utilizaron GNDVI y área de dosel para evaluar la respuesta del frijol a la sequía y deficiencia de nitrógeno, en diferentes estaciones del año. Para todas las variedades analizadas, el GNDVI tuvo correlación significativa con el rendimiento del cultivo bajo condiciones de sequía. Además, se evidenció una alta correlación entre el valor de este índice de vegetación determinado a los 60 y 75 días después de siembra (DDS) con el contenido de nitrógeno en la hoja para todos los porcentajes evaluados.

Ranjan et al. [17], utilizaron una cámara multispectral para evaluar 25 índices de vegetación en tres etapas fenológicas de acuerdo con su relación con el rendimiento del frijol bajo diferentes condiciones de manejo. Se encontró que los índices IPVI, TDVI, NLI y MNLI mostraron mejor correlación con el rendimiento y el efecto de las labores de manejo. Además, evidenciaron que otros índices como NDVI, RDVI, SAVI, MSAVI y OSAVI pueden proveer información complementaria a los anteriores.

El propósito de esta investigación fue identificar la mayor asociación de bandas multispectrales e índices de vegetación con componentes de rendimiento del cultivo de frijol, obtenidos mediante sensores aerotransportados en condiciones de campo en Costa Rica.

Materiales y Métodos

Área de estudio

La recolección de datos para la investigación se realizó en tres zonas productoras de frijol de Costa Rica: Caño Negro (10,892015°, -84,786122°), Pavón de Los Chiles (10,837449°, -84,618770°) y la Estación Experimental Agrícola Fabio Baudrit Moreno (EEAFBM), ubicada en La Garita de Alajuela (10,00805°, -84,266611°). El estudio incluyó la variedad Cabécar en Caño Negro, la variedad Matambú en Pavón de Los Chiles y en la EEAFBM las variedades Diquís y Nambí en el lote 15, y Cabécar y Nambí en el lote 32.

En la EEAFBM se trabajó en dos lotes experimentales, identificados como EEAFBM 15 y EEAFBM 32. El cultivo se estableció mediante siembra a espeque, colocando 15 semillas por metro lineal. En Caño Negro y El Pavón de Los Chiles, la siembra se realizó de forma mecanizada mediante una sembradora neumática de precisión marca Jumil de seis líneas, acoplada a un tractor. La distribución de las semillas se efectuó mediante un sistema de vacío generado por una turbina, el cual permitió la dosificación individual de las semillas a través de discos perforados. La densidad de siembra también correspondió a 15 semillas por metro lineal.

Una semana después de la siembra se aplicó una fuente fosfatada a razón de 180 kg ha⁻¹ de la fórmula 10-30-10. Para el manejo de insectos se realizó la aplicación de un insecticida piretroide a una dosis de 1 mL L⁻¹. El control de malezas durante los primeros 30 días después de la siembra se efectuó mediante aplicaciones de Fomesafen a razón de 375 mL ha⁻¹ y Fluazifop-butil a 1 L ha⁻¹. Para el manejo fitosanitario de enfermedades se realizaron aplicaciones alternadas de Carbendazim a una dosis de 10 mL L⁻¹ y Azoxistrobina a 1 g L⁻¹ durante el ciclo del cultivo.

Diseño de investigación

El diseño de la investigación fue de carácter observacional, ya que no se manipularon variables independientes ni se establecieron tratamientos experimentales.

Los vuelos fotogramétricos se realizaron durante el estado fenológico R5 (floración), entre 40 y 52 días antes de la cosecha [18].

Se realizaron los vuelos en condiciones de cielo despejado. Las imágenes fueron capturadas a una altitud promedio de 80 metros, con traslapes frontales y laterales del 80% entre capturas, lo que permitió obtener una resolución espacial aproximada de 3,8 a 4,0 cm. La velocidad de vuelo se estableció en 6 metros por segundo durante la captura de datos. Estos parámetros fueron configurados previo a las misiones de vuelo utilizando el software DJI Pilot.

Previo a cada uno de los vuelos se realizó la identificación y georreferenciación de puntos de control utilizando un GPS de alta precisión (Trimble Geo 7X) para rectificar las imágenes que fueron procesadas con el programa Pix4D para generar el ortomosaico de cada área monitoreada.

Los datos multiespectrales se obtuvieron mediante el sensor MicaSense Altum™ serie AL04 (MicaSense, Inc. Seattle, Washington, Estados Unidos) acoplado en un dron DJI Matrice 210 (Da-Jiang Innovations Science and Technology Co., Shenzhen, China). Este sensor registró valores digitales correspondientes a la banda azul ($475 \text{ nm} \pm 32 \text{ nm}$), verde ($560 \text{ nm} \pm 16,5 \text{ nm}$), rojo ($668 \text{ nm} \pm 7 \text{ nm}$), borde rojo ($717 \text{ nm} \pm 6 \text{ nm}$) e infrarrojo cercano ($842 \text{ nm} \pm 28,5 \text{ nm}$), junto a registros en centikelvins de la banda térmica (infrarrojo de onda larga o LWIR) ($11 \mu\text{m} \pm 3 \mu\text{m}$).

El resultado de cada vuelo consistió en conjuntos de imágenes crudas (sin procesar), en las cuales cada píxel representó una ubicación geográfica con números digitales asociados a cada banda.

El procedimiento de calibración se efectuó mediante la captura de imágenes de un panel de calibración proporcionado por MicaSense antes y después de cada misión. Dichos datos se expresaron como una firma espectral de reflectancia absoluta, con valores comprendidos entre 0 y 1, los cuales representan la proporción de la luz reflejada en el rango de 400 a 850 nm, con incrementos de 1 nm. Se emplearon cinco bandas en la recolección de datos, las cuales fueron corregidas utilizando el panel de calibración radiométrica.

La corrección se llevó a cabo junto con la rectificación y ensamblaje de las imágenes, utilizando el software Pix4Dmapper Versión 4.5.6 (Pix4D SA, 2023). Se utilizó el proceso predeterminado "Ag Multispectral" para generar ortomosaicos (tipo ráster) correspondientes a cada banda.

Con este procedimiento se generaron ortomosaicos de las zonas de estudio con los valores de las reflectancias espectrales correspondientes a las bandas azul, roja, verde, infrarrojo cercano (NIR, por sus siglas en inglés) y borde rojo (Red-Edge). Posteriormente, se calcularon índices de vegetación, entre ellos el índice de vegetación de diferencia normalizada (NDVI), el índice normalizado de diferencia verde-rojo (NGRDI), el cociente simple (SR), el índice de diferencia normalizada de borde rojo (NDRE), el índice de clorofila verde (GCI) y el índice de clorofila Red-Edge (CI Red-Edge) (ver Cuadro 1).

Cuadro 1. Índices de vegetación utilizados para la evaluación del cultivo de frijol.

Índice	Fórmula
Índice de Vegetación Diferencia Normalizada (NDVI)	$\frac{R_{NIR} - R_{ROJA}}{R_{NIR} + R_{ROJA}}$
Índice de Diferencia Verde Rojo Normalizado (NGRDI)	$\frac{R_{VERDE} - R_{ROJA}}{R_{VERDE} + R_{ROJA}}$
Cociente Simple (SR)	$\frac{R_{NIR}}{R_{ROJA}}$
Índice de Borde Rojo (NDRE)	$\frac{R_{NIR} - R_{BORDE ROJO}}{R_{NIR} + R_{BORDE ROJO}}$
Índice de Clorofila Verde (GCI)	$\frac{R_{NIR}}{R_{VERDE}} - 1$
Índice de Clorofila Red-Edge (CI Red-Edge)	$\frac{R_{NIR}}{R_{BORDE ROJO}} - 1$

Nota. La banda “NIR” representa la región del espectro electromagnético del infrarrojo cercano (*near-infrared*).

A partir de estos productos, se identificó patrones de variabilidad espacial del vigor del cultivo, y se utilizó como referencia principal el índice de vegetación NDRE debido a su sensibilidad a los contenidos de clorofila y a condiciones de nutrición [19]NDRE, GNDVI, and SAVI are widely applied to estimate vine vigor, canopy structure, and water status. Beyond agronomic traits, UAV-derived indices can inform grape composition, including sugar content (°Brix (Figura 1).




Figura 1. Extracción de los valores digitales de NDRE por subparcela, EEAFBM, La Garita, Costa Rica.

La discriminación de estas zonas de vigor se realizó mediante el índice de Moran, el cual permitió evaluar la autocorrelación espacial e identificar la existencia de patrones de agrupamiento (*clustering*) o dispersión entre las categorías de vigor. Para ello, se siguió una metodología similar a la propuesta por Posite et al [20].

Con base en esta variabilidad, se establecieron parcelas de muestreo georreferenciadas distribuidas de acuerdo con las diferentes condiciones de vigor presentes en cada lote (Figura 2), de manera que la información obtenida fuera representativa del comportamiento agronómico del cultivo.




Figura 2. Distribución de parcelas evaluadas según diferentes niveles de vigor estimados con el índice de vegetación NDRE.

Posteriormente, se delimitaron parcelas digitales de un metro lineal dentro de cada ortomosaico, en las cuales se definieron las áreas de interés para la extracción de datos multispectrales, que incluyeron valores de reflectancia en las distintas bandas y los índices de vegetación previamente descritos.

Las subparcelas se representaron vectorialmente mediante polígonos creados con QGIS (QGIS Development Team, 2023), versión 3.32.0. Se generaron polígonos virtuales por vuelo, los cuales se almacenaron en formato ESRI Shapefile.

Finalmente, se extrajeron los valores de píxeles de los rásteres delimitados geográficamente por las capas vectoriales utilizando Python versión 3.11.5 y las librerías GDAL/OGR (GDAL/OGR contributors, 2022) para la manipulación de datos geoespaciales. Así, se obtuvieron los valores de reflectancia de interés, los cuales se almacenaron en formato CSV.

Datos de rendimiento

Durante la etapa fenológica R9 (Cosecha) se recolectaron las vainas de cada una de las parcelas definidas como puntos de muestreo, y se determinaron los componentes de rendimiento por cada metro lineal de cultivo, tales como: peso de 100 granos (100PG, g/m), número de vainas por metro (NV, vainas/m), número de plantas (NP, plantas/m), número de granos (NG, granos/m) y peso total de granos (PTG, g/m).

En total, se muestrearon 141 subparcelas, obteniéndose 141 observaciones para cada uno de los componentes del rendimiento. La distribución de las muestras fue la siguiente: 42 muestras de la variedad Cabécar en Caño Negro; 42 muestras de la variedad Matambú en Pavón de Los Chiles; 42 muestras de las variedades Diquís y Nambí en el lote 32 de la EEAFBM; y 15 muestras de las variedades Cabécar y Nambí en el lote 15 de la EEAFBM.

Correlación de Pearson y ajuste de los modelos lineales

La información del rendimiento por parcela y los promedios de reflectancias, e índices, se analizaron por medio del método de correlación de Pearson para determinar la relación lineal entre estas variables. Esto se realizó con el paquete estadístico JMP Pro15.

Mediante el mismo software se verificó el cumplimiento de los supuestos de normalidad y homocedasticidad de los datos. Posteriormente, se ajustaron modelos de regresión lineal por mínimos cuadrados ordinarios para estimar el componente de rendimiento que presentó la mayor correlación con los índices de vegetación. En dichos modelos, los índices de vegetación se emplearon como variables predictoras y el componente de rendimiento como variable respuesta, obteniéndose la ecuación de regresión correspondiente. La bondad de ajuste de cada modelo se evaluó mediante el coeficiente de determinación (R^2) (Ec. 1):

$$R^2 = 1 - \left(\frac{SC_{residuos}}{SC_{total}} \right) \quad (1)$$

El $SC_{residuos}$ es la suma de los cuadrados del error residual de las predicciones, y SC_{total} es la suma total de cuadrados de los datos u observaciones.

Resultados y Discusión

Análisis de correlación independiente, según ubicación y variedad de frijol.

Se realizaron análisis de correlación de Pearson entre los valores de los componentes de rendimiento y la reflectancia de las bandas analizadas e índices de vegetación. Inicialmente, estas correlaciones se realizaron para cada uno de los diferentes sitios (Caño Negro, El Pavón y EEAFBM) y materiales genéticos de frijol con los que se trabajó (Matambú, Cabécar, Nambí y Diquís). Estos valores se presentaron en las figuras 3 y 4.

En las matrices de correlación presentadas, los valores superiores a 0,75 hasta cercanos a 1 se observan en color azul. Mientras que los valores menores a -0,75 se presentan en rojo oscuro. En ambos casos, estos valores indicaron una relación lineal fuerte entre las variables analizadas. Las cuadrículas de color blanco y colores claros correspondieron a una baja correlación entre los datos.

Pavón

Variables	Número de plantas	Número de vainas	Peso de granos (g)	Peso de 100 granos (g)	Número de granos	Borde rojo	NIR	Rojo	Verde	NDVI	NGDRI	SR	NDRE	CI Red-Edge	GCI
Número de plantas	1,00														
Número de vainas	0,39	1,00													
Peso de granos (g)	0,41	0,96	1,00												
Peso de 100 granos (g)	-0,24	-0,29	-0,19	1,00											
Número de granos	0,41	0,95	0,95	-0,37	1,00										
Borde rojo	0,48	0,61	0,70	-0,19	0,65	1,00									
NIR	0,43	0,89	0,89	-0,22	0,86	0,84	1,00								
Rojo	-0,38	-0,82	-0,84	0,24	-0,80	-0,83	-0,96	1,00							
Verde	0,13	-0,10	0,02	-0,06	-0,04	0,43	0,04	-0,04	1,00						
NDVI	0,42	0,82	0,84	-0,22	0,80	0,89	0,97	-0,98	0,12	1,00					
NGDRI	0,45	0,77	0,81	-0,25	0,77	0,91	0,95	-0,96	0,22	0,98	1,00				
SR	0,42	0,89	0,88	-0,24	0,85	0,78	0,99	-0,95	-0,04	0,96	0,93	1,00			
NDRE	0,39	0,90	0,89	-0,22	0,86	0,77	0,99	-0,97	-0,05	0,96	0,93	0,99	1,00		
CI Red-Edge	0,38	0,91	0,88	-0,20	0,85	0,72	0,98	-0,94	-0,10	0,93	0,90	0,99	0,99	1,00	
GCI	0,38	0,91	0,88	-0,21	0,85	0,71	0,98	-0,94	-0,12	0,93	0,90	0,99	0,99	1,00	1,00

Caño Negro

Variables	Número de plantas	Número de vainas	Peso de granos (g)	Peso de 100 granos (g)	Número de granos	Borde rojo	NIR	Rojo	Verde	NDVI	NGDRI	SR	NDRE	CI Red-Edge	GCI
Número de plantas	1,00														
Número de vainas	0,27	1,00													
Peso de granos (g)	0,35	0,83	1,00												
Peso de 100 granos (g)	0,07	0,03	0,29	1,00											
Número de granos	0,38	0,85	0,98	0,12	1,00										
Borde rojo	0,18	0,52	0,59	0,00	0,59	1,00									
NIR	0,21	0,68	0,72	0,12	0,70	0,89	1,00								
Rojo	-0,29	-0,67	-0,64	-0,18	-0,65	-0,68	-0,75	1,00							
Verde	0,18	0,40	0,49	-0,06	0,50	0,97	0,80	-0,54	1,00						
NDVI	0,28	0,69	0,70	0,16	0,70	0,85	0,89	-0,95	0,73	1,00					
NGDRI	0,27	0,65	0,66	0,08	0,67	0,90	0,88	-0,93	0,80	0,99	1,00				
SR	0,23	0,73	0,70	0,12	0,70	0,82	0,96	-0,85	0,69	0,93	0,92	1,00			
NDRE	0,26	0,74	0,72	0,15	0,71	0,66	0,91	-0,78	0,53	0,85	0,79	0,94	1,00		
CI Red-Edge	0,22	0,73	0,71	0,18	0,70	0,66	0,93	-0,74	0,52	0,82	0,76	0,95	0,98	1,00	
GCI	0,20	0,73	0,71	0,19	0,69	0,67	0,92	-0,77	0,51	0,84	0,79	0,96	0,97	0,99	1,00

Figura 3. Correlaciones entre los componentes de rendimiento y los datos multiespectrales. Las matrices de correlación se construyeron a partir de los datos recolectados en diferentes ubicaciones (El Pavón y Caño Negro) y de distintos materiales genéticos de frijol.

EEAFBM 15

Variables	Número de plantas	Número de vainas	Peso de granos (g)	Peso de 100 granos (g)	Número de granos	Borde rojo	NIR	Rojo	Verde	NDVI	NGDRI	SR	NDRE	CI Red-Edge	GCI
Número de plantas	1,00														
Número de vainas	0,85	1,00													
Peso de granos (g)	0,88	0,80	1,00												
Peso de 100 granos (g)	0,10	0,21	-0,02	1,00											
Número de granos	0,83	0,80	0,99	-0,02	1,00										
Borde rojo	0,20	0,10	0,18	-0,30	0,10	1,00									
NIR	0,50	0,47	0,50	-0,04	0,41	0,83	1,00								
Rojo	-0,44	-0,48	-0,42	-0,43	-0,38	0,07	-0,44	1,00							
Verde	-0,04	-0,18	-0,08	-0,43	-0,13	0,89	0,49	0,49	1,00						
NDVI	0,51	0,51	0,50	0,25	0,42	0,39	0,81	-0,87	-0,05	1,00					
NGDRI	0,44	0,42	0,42	0,15	0,32	0,62	0,90	-0,73	0,22	0,94	1,00				
SR	0,52	0,55	0,53	0,32	0,45	0,38	0,80	-0,84	-0,07	0,95	0,94	1,00			
NDRE	0,59	0,67	0,60	0,33	0,55	0,09	0,63	-0,88	-0,35	0,90	0,74	0,88	1,00		
CI Red-Edge	0,76	0,81	0,68	0,26	0,65	0,00	0,46	-0,67	-0,35	0,65	0,53	0,70	0,80	1,00	
GCI	0,74	0,78	0,68	0,28	0,64	0,01	0,47	-0,70	-0,34	0,67	0,56	0,73	0,80	1,00	1,00

EEAFBM 32

Variables	Número de plantas	Número de vainas	Peso de granos (g)	Peso de 100 granos (g)	Número de granos	Borde rojo	NIR	Rojo	Verde	NDVI	NGDRI	SR	NDRE	CI Red-Edge	GCI
Número de plantas	1,00														
Número de vainas	0,55	1,00													
Peso de granos (g)	0,46	0,95	1,00												
Peso de 100 granos (g)	-0,09	-0,18	0,04	1,00											
Número de granos	0,47	0,98	0,97	-0,18	1,00										
Borde rojo	0,58	0,84	0,78	-0,19	0,81	1,00									
NIR	0,11	0,72	0,73	-0,19	0,76	0,61	1,00								
Rojo	-0,69	-0,77	-0,68	0,25	-0,73	-0,88	-0,38	1,00							
Verde	-0,54	-0,11	-0,01	0,07	-0,02	-0,36	0,49	0,54	1,00						
NDVI	0,56	0,85	0,80	-0,25	0,84	0,92	0,68	-0,92	-0,20	1,00					
NGDRI	0,55	0,88	0,82	-0,25	0,87	0,90	0,69	-0,91	-0,17	0,99	1,00				
SR	0,60	0,91	0,84	-0,24	0,88	0,96	0,64	-0,89	-0,31	0,92	0,93	1,00			
NDRE	0,57	0,85	0,79	-0,21	0,83	0,99	0,63	-0,90	-0,33	0,95	0,92	0,96	1,00		
CI Red-Edge	0,58	0,84	0,78	-0,19	0,81	1,00	0,61	-0,89	-0,37	0,92	0,90	0,96	0,99	1,00	
GCI	0,61	0,85	0,77	-0,22	0,81	0,99	0,60	-0,87	-0,38	0,90	0,88	0,97	0,98	0,99	1,00

Figura 4. Correlaciones entre los componentes de rendimiento y los datos multispectrales. Las matrices de correlación se construyeron a partir de los datos recolectados en diferentes ubicaciones (EEAFBM 15 y EEAFBM 32) y de distintos materiales genéticos de frijol.

Correlación entre componentes de rendimiento del cultivo de frijol.

Al calcular los coeficientes de correlación entre las variables asociadas a los componentes de rendimiento en los cuatro escenarios analizados, se observó que la variable de respuesta NV presentó las correlaciones más fuertes en todos los sitios evaluados, por lo que fue el componente de rendimiento con la mayor relación lineal con la reflectancia y los índices de vegetación analizados.

Otras variables respuesta, como NG y PTG, también mostraron altos valores de correlación, lo que indicó una relación lineal respecto a los datos multiespectrales. Sin embargo, estas correlaciones fueron inferiores a las obtenidas por NV (ver Figura 3 y 4). El número de plantas, así como el peso de 100 granos, no presentaron correlaciones significativas.

Debido a que la variable respuesta NV presentó de forma consistente las correlaciones más altas en los cuatro escenarios evaluados, el análisis posterior se realizó utilizando este componente de rendimiento.

Correlación de NV con los valores de reflectancia de las bandas e índices de vegetación.

Dado que el componente NV mostró la relación lineal más fuerte con las bandas de reflectancia y los índices de vegetación evaluados, fue seleccionado como la variable con mayor capacidad de asociación con la información multiespectral. Esta selección permitió enfocar el análisis en la variable con mayor relevancia espectral, evitando incluir componentes de rendimiento con menor relación con las variables derivadas de sensores multiespectrales. De esta manera, se optimizó el uso de los datos disponibles hacia una variable con mayor potencial de aplicación práctica bajo condiciones de campo.

Los valores de correlación para el lote 15 de la EEAFBM, en el cual se utilizó la variedad Diquís y Nambí, presentó una fuerte correlación de 0,81 entre NV y el índice CI Red-Edge (Figura 4). Otro índice con el que se obtuvo una alta correlación ($r = 0,78$) fue el GCI. El NDRE mostró valores de correlación de 0,67 con NV. Adicionalmente, los resultados mostraron que tanto el índice SR como el NDVI presentaron correlaciones moderadas con NV, con un valor de $r = 0,5$.

En el lote 32 de la EEAFBM, se utilizaron las variedades Cabécar y Nambí. Los índices que mejor correlacionaron con NV fueron SR con un valor de 0,91, NGRDI con 0,88; NDVI, GCI y NDRE, con valores de 0,85. El índice CI Red-Edge y la banda borde rojo alcanzaron valores de 0,84. Además, la banda Roja y NIR presentaron valores de correlación de 0,77 y 0,72 respectivamente, lo cual indicó que la mayoría de las bandas y los índices evaluados obtuvieron una buena correlación con NV, indistintamente del sitio y de la línea de frijol utilizada.

En Caño Negro se evaluó un lote de producción de frijol Cabécar. Los valores de correlación de las bandas e índices de vegetación fueron menores a los obtenidos en los dos escenarios anteriores.

El índice NDRE mostró una correlación de 0,74 con NV, los índices SR, GCI y CI Red-Edge, exhibieron valores de 0,73. Mientras que los índices NDVI, NGRDI, y las bandas NIR y roja, presentaron valores entre 0,65 y 0,69.

En la zona de Pavón, la variedad de frijol que se analizó fue Matambú. La correlación de los índices de vegetación y los valores de reflectancia de las bandas evaluadas con respecto a NV fue mayor que la observada en Caño Negro. En esta zona la correlación con los índices GCI y CI Red-Edge fue de 0,91. Así mismo, para NDRE, SR y la banda NIR, fue de 0,89.

Los índices NDVI y NGRDI y las bandas NIR y Rojo obtuvieron una correlación con NV de 0,82, 0,77, 0,89 y -0,82 respectivamente. Independientemente del sitio, la banda verde tuvo una baja correlación con los componentes de rendimiento.

Correlación del número de vainas con variables espectrales mediante la integración de localidades y variedades evaluadas

La evaluación conjunta de los diferentes escenarios (sitios y variedades) permitió evaluar el efecto de la variabilidad sobre los valores de correlación de las variables de respuesta ligadas a componentes de rendimiento y las bandas e índices de vegetación.

Si bien en todos los casos se observaron índices y bandas con correlaciones superiores a 0,6 con variables como NV (Figura 5), la ubicación y la variedad de frijol en conjunto podría tener un efecto sobre las relaciones lineales (Figura 3 y 4).

Variables	Número de plantas	Número de vainas	Peso de granos (g)	Peso de 100 granos (g)	Número de granos	Borde rojo	NIR	Rojo	Verde	NDVI	NGDRI	SR	NDRE	CI Red-Edge	GCI
Número de plantas	1.00														
Número de vainas	0.44	1.00													
Peso de granos (g)	0.48	0.75	1.00												
Peso de 100 granos (g)	0.06	-0.05	0.37	1.00											
Número de granos	0.46	0.85	0.93	0.06	1.00										
Borde rojo	0.20	-0.03	0.25	0.41	0.14	1.00									
NIR	0.14	0.62	0.28	-0.15	0.39	-0.02	1.00								
Rojo	-0.42	-0.71	-0.58	-0.17	-0.59	0.04	-0.57	1.00							
Verde	-0.20	-0.12	-0.15	-0.16	-0.10	0.38	0.39	0.34	1.00						
NDVI	0.32	0.68	0.54	0.18	0.56	0.11	0.78	-0.91	0.01	1.00					
NGDRI	0.37	0.69	0.59	0.18	0.60	0.20	0.77	-0.86	0.15	0.95	1.00				
SR	0.36	0.77	0.56	0.08	0.59	-0.05	0.82	-0.87	-0.08	0.88	0.89	1.00			
NDRE	0.28	0.69	0.46	0.17	0.48	-0.01	0.80	-0.86	-0.12	0.92	0.82	0.91	1.00		
CI Red-Edge	0.29	0.67	0.36	0.06	0.40	-0.05	0.85	-0.74	-0.03	0.82	0.75	0.90	0.94	1.00	
GCI	0.32	0.73	0.41	-0.04	0.48	-0.16	0.83	-0.77	-0.11	0.81	0.74	0.92	0.92	0.98	1.00

Figura 5. Correlaciones de componentes de rendimiento con todos los materiales de frijol en distintas ubicaciones.

Al combinar los datos procedentes de todas las localidades y materiales, se observó (Figura 5) que NV fue la variable respuesta que presentó los mayores valores de correlación con respecto a las bandas e índices de vegetación, similar a lo reportado en estudios con soja, donde el NDVI y otros índices multispectrales mostraron fuertes relaciones con el número de vainas y el rendimiento de grano [21].

Además, las variables respuesta NG y PTG presentaron correlaciones de 0,85 y 0,75 con respecto a NV, respectivamente, lo cual evidenció la relación existente entre los componentes de rendimiento del cultivo. Estos resultados respaldaron la selección de NV como la variable con mayor potencial para su estimación mediante información multispectral, debido a su mayor asociación con las bandas e índices evaluados.

Los índices de vegetación SR y GCI fueron los que presentaron las mayores correlaciones en comparación a otros índices de vegetación y bandas, con un valor de 0,77 respecto a NV. La banda roja presentó un valor de -0,71, lo cual indicó una alta correlación negativa con NV.

Además, otros índices de vegetación como NDRE, NGRDI y NDVI presentaron correlaciones entre 0,68 y 0,69 con esta variable. Por su parte, la banda NIR alcanzó una correlación de 0,62 con esta variable.

Ecuaciones de predicción de número de vainas con los valores de índices de vegetación.

Como consecuencia de las relaciones encontradas entre NV y los índices SR y GCI, se ajustaron modelos lineales simples, para obtener una ecuación donde se relacione el NV con el índice SR y GCI como predictor.

Cuando se utilizó el índice SR, el modelo fue significativo ($p < 0,05$) y es expresado por la ecuación 2:

$$\text{Número de vainas} = 6,28 \times SR + 16,89 \quad (2)$$

La relación lineal entre el índice SR y el número de vainas se presenta en la Figura 6. El modelo obtuvo un coeficiente de determinación (R^2) de 0,59, indicando que el índice SR explicó el 59 % de la variabilidad observada en el número de vainas.




Figura 6. Gráfico de dispersión entre el índice SR y el número de vainas ($n = 141$) con línea de tendencia de predicción del modelo lineal simple.

Al utilizar el Índice de Clorofila Verde (GCI) como predictor, y ajustar el modelo lineal simple este también resultó estadísticamente significativo (F , $p < 0,05$) y se puede expresar por la ecuación 3:

$$\text{Número de vainas} = 23,13 \times GCI + 3,93 \quad (3)$$

La relación entre el índice GCI y NV presentó un R^2 de 0,54 (Figura 7).




Figura 7. Gráfico de dispersión entre el índice GCI y el número de vainas (n=141) con línea de tendencia de predicción del modelo lineal simple.

Existen diversas publicaciones que han evaluado el uso de sensores remotos e índices de vegetación para analizar su relación con los componentes de rendimiento en el cultivo frijol; sin embargo, estos estudios se han desarrollado principalmente bajo condiciones uniformes o controladas, generalmente en una misma zona experimental, sin considerar el efecto que puede generar una mayor variabilidad ambiental y genética sobre los resultados [5], [22], limitando la extrapolación de sus conclusiones a contextos más generales y menos controlados como lo son los campos de producción en Costa Rica.

Adicionalmente, en investigaciones similares no han reportado correlaciones entre variables espectrales y componentes de rendimiento superiores a 0,50 durante la etapa fenológica R5 [5], [23].

En contraste, el presente estudio identificó asociaciones más fuertes entre los índices de vegetación y el número de vainas (NV) en la etapa R5, alcanzando coeficientes de correlación de Pearson de hasta 0,77.

La implementación de modelos lineales permitió identificar los índices de vegetación SR y GCI como las variables espectrales con mayor capacidad para explicar la variabilidad observada en el número de vainas (NV), con un coeficiente de determinación superior al 50 %.

Estos resultados respaldan el uso de ambos índices como herramientas para el monitoreo del cultivo y constituyen una base para futuras aplicaciones orientadas a la estimación temprana del potencial productivo del cultivo de frijol.

Los métodos tradicionales de estimación de producción son lentos, subjetivos y de alto costo, además de estar limitados a áreas puntuales [24]. En contraste, los enfoques basados en sensores remotos y modelado predictivo permitirían realizar estimaciones del número de vainas con 40-52 días de anticipación a la cosecha, periodo correspondiente a la fase R5 del cultivo [18]. La implementación de esta tecnología podría facilitar que los productores anticipen escenarios productivos y con esto mejorar la toma de decisiones comerciales y agronómicas mediante información espacialmente explícita y oportuna.

Conclusiones

Los resultados demostraron que la teledetección mediante sensores multiespectrales y el cálculo de índices de vegetación, como el cociente simple (SR) y el índice de clorofila verde (GCI), presentaron correlaciones superiores a 0,77 con el número de vainas (NV) en frijol común durante la etapa fenológica R5, lo que permitió identificarlos como variables predictoras de este componente de rendimiento.

Los modelos lineales desarrollados a partir de los índices SR y GCI alcanzaron valores de R^2 de hasta 0,59 para la predicción del número de vainas, lo que respalda su utilidad como variables espectrales para la estimación de este componente de rendimiento, aun bajo la variabilidad asociada a las diferentes zonas de producción y materiales genéticos evaluados.

El análisis espectral evidenció que la banda roja presentó una relación inversa con el número de vainas ($r = -0,71$), por lo que se identificó como una variable espectral de interés para evaluaciones preliminares del desarrollo del cultivo. Este resultado sugiere que, para aplicaciones de monitoreo, podrían evaluarse plataformas de adquisición de imágenes de menor costo, como drones comerciales equipados con sensores RGB, siempre que los productos derivados sean previamente calibrados y validados bajo las condiciones específicas del cultivo.

Agradecimientos

Esta investigación se ejecutó gracias al apoyo del Instituto Nacional de Innovación y Transferencia de Tecnología Agropecuaria (INTA), de la Vicerrectoría de Investigación y de la Estación Experimental Agrícola Fabio Baudrit Moreno de la Universidad de Costa Rica. Al proyecto KoLFACI (Iniciativa de Cooperación para la Alimentación y la Agricultura entre Corea y Latinoamérica) y la Alianza Bioversity – CIAT.

Referencias

- [1] I. Hayat, A. Ahmad, T. Masud, A. Ahmed, and S. Bashir, "Nutritional and Health Perspectives of Beans (*Phaseolus vulgaris* L.): An Overview," *Critical Reviews in Food Science and Nutrition*, vol. 54, no. 5, pp. 580–592, Jan. 2014, doi: 10.1080/10408398.2011.596639.
- [2] K. O'Neal, "Semilla UCR: Así contribuimos para que los frijoles lleguen a su mesa," Universidad de Costa Rica, Aug. 13, 2020. Accessed: Oct. 23, 2025. [Online]. Available: <https://www.ucr.ac.cr/noticias/2020/08/13/semilla-ucr-asi-contribuimos-para-que-los-frijoles-lleguen-a-su-mesa.html>
- [3] D. Brown *et al.*, "Rank-based data synthesis of common bean on-farm trials across four Central American countries," *Crop Science*, vol. 62, no. 6, pp. 2246–2266, Nov. 2022, doi: 10.1002/csc2.20817.
- [4] D. Gomez *et al.*, "Advancing common bean (*Phaseolus vulgaris* L.) disease detection with YOLO driven deep learning to enhance agricultural AI," *Sci Rep*, vol. 14, no. 1, p. 15596, Jul. 2024, doi: 10.1038/s41598-024-66281-w.
- [5] D. Saravia *et al.*, "Yield Prediction of Four Bean (*Phaseolus vulgaris*) Cultivars Using Vegetation Indices Based on Multispectral Images from UAV in an Arid Zone of Peru," *Drones*, vol. 7, no. 5, p. 325, May 2023, doi: 10.3390/drones7050325.
- [6] S. B. Dhal and D. Kar, "Transforming Agricultural Productivity with AI-Driven Forecasting: Innovations in Food Security and Supply Chain Optimization," *Forecasting*, vol. 6, no. 4, pp. 925–951, Oct. 2024, doi: 10.3390/forecast6040046.
- [7] F. Farrokhi and H. S. Pellegrina, "Trade, Technology, and Agricultural Productivity," *Journal of Political Economy*, vol. 131, no. 9, pp. 2509–2555, Sep. 2023, doi: 10.1086/724319.
- [8] OECD, *Fostering Productivity and Competitiveness in Agriculture*. OECD, 2011. doi: 10.1787/9789264166820-en.

- [9] G. Singhal, B. Bansod, L. Mathew, J. Goswami, B. U. Choudhury, and P. L. N. Raju, "Chlorophyll estimation using multi-spectral unmanned aerial system based on machine learning techniques," *Remote Sensing Applications: Society and Environment*, vol. 15, p. 100235, Aug. 2019, doi: 10.1016/j.rsase.2019.100235.
- [10] E. E. Da Silva, F. H. Rojo Baio, L. P. Ribeiro Teodoro, C. A. Da Silva Junior, R. S. Borges, and P. E. Teodoro, "UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation," *Remote Sensing Applications: Society and Environment*, vol. 18, p. 100318, Apr. 2020, doi: 10.1016/j.rsase.2020.100318.
- [11] T. S. T. Tanaka *et al.*, "Review of Crop Phenotyping in Field Plot Experiments Using UAV-Mounted Sensors and Algorithms," *Drones*, vol. 8, no. 6, p. 212, May 2024, doi: 10.3390/drones8060212.
- [12] D. Li, C. Li, Y. Yao, M. Li, and L. Liu, "Modern imaging techniques in plant nutrition analysis: A review," *Computers and Electronics in Agriculture*, vol. 174, p. 105459, Jul. 2020, doi: 10.1016/j.compag.2020.105459.
- [13] T. Javornik, K. Carović-Stanko, J. Gunjača, M. Vidak, and B. Lazarević, "Monitoring Drought Stress in Common Bean Using Chlorophyll Fluorescence and Multispectral Imaging," *Plants*, vol. 12, no. 6, p. 1386, Mar. 2023, doi: 10.3390/plants12061386.
- [14] L. T. Boechat, F. D. A. D. C. Pinto, T. J. D. Paula Júnior, D. M. Queiroz, and H. Teixeira, "Detecção do mofo-branco no feijoeiro, utilizando características espectrais," *Rev. Ceres*, vol. 61, no. 6, pp. 907–915, Dec. 2014, doi: 10.1590/0034-737X201461060004.
- [15] G. Girón and A. Pagani, "Evaluación del índice de vegetación diferencial normalizado para delinear zonas de manejo de nitrógeno para el cultivo de maíz," *INTA*, vol. Memoria Técnica 2017-2018, 2018.
- [16] S. Sankaran, J. Zhou, L. R. Khot, J. J. Trapp, E. Mndolwa, and P. N. Miklas, "High-throughput field phenotyping in dry bean using small unmanned aerial vehicle based multispectral imagery," *Computers and Electronics in Agriculture*, vol. 151, pp. 84–92, Aug. 2018, doi: 10.1016/j.compag.2018.05.034.
- [17] R. Ranjan *et al.*, "Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology," *Information Processing in Agriculture*, vol. 6, no. 4, pp. 502–514, Dec. 2019, doi: 10.1016/j.inpa.2019.01.005.
- [18] J. A. Clavijo Michelangeli, M. Bhakta, S. A. Gezan, K. J. Boote, and C. E. Vallejos, "From flower to seed: identifying phenological markers and reliable growth functions to model reproductive development in the common bean (*Phaseolus vulgaris* L.)," *Plant Cell & Environment*, vol. 36, no. 11, pp. 2046–2058, Nov. 2013, doi: 10.1111/pce.12114.
- [19] A. Vera-Esmeraldas, S. Pizarro-Oteiza, M. Labbé, F. Rojo, and F. Salazar, "UAV-Based Spectral and Thermal Indices in Precision Viticulture: A Review of NDVI, NDRE, SAVI, GNDVI, and CWSI," *Agronomy*, vol. 15, no. 11, p. 2569, Nov. 2025, doi: 10.3390/agronomy15112569.
- [20] V. R. Posite *et al.*, "Decoding Vegetation Dynamics in High-Altitude Tropical Ecosystems: A Spatio-Temporal Assessment Using Multi-Index and Biophysical Remote Sensing Products (2002–2024)," *Earth Syst Environ*, Aug. 2025, doi: 10.1007/s41748-025-00750-8.
- [21] M. Nolasco, G. Ovando, S. Sayago, I. Magario, and M. Bocco, "Estimating soybean yield using time series of anomalies in vegetation indices from MODIS," *International Journal of Remote Sensing*, vol. 42, no. 2, pp. 405–421, Jan. 2021, doi: 10.1080/01431161.2020.1809736.
- [22] V. A. Filla, A. P. Coelho, J. V. T. Bettiol, F. T. Leal, L. B. Lemos, and D. L. Rosalen, "Model performance in estimating the yield of common bean cultivars," *RCA*, vol. 54, no. 1, 2023, doi: 10.5935/1806-6690.20230002.
- [23] H. F. E. De Oliveira *et al.*, "Geotechnologies in Biophysical Analysis through the Applicability of the UAV and Sentinel-2A/MSI in Irrigated Area of Common Beans: Accuracy and Spatial Dynamics," *Remote Sensing*, vol. 16, no. 7, p. 1254, Apr. 2024, doi: 10.3390/rs16071254.
- [24] A. M. Ali *et al.*, "Crop Yield Prediction Using Multi Sensors Remote Sensing (Review Article)," *The Egyptian Journal of Remote Sensing and Space Sciences*, vol. 25, no. 3, pp. 711–716, Dec. 2022, doi: 10.1016/j.ejrs.2022.04.006.

Declaración sobre uso de Inteligencia Artificial (IA)

Los autores aquí firmantes declaramos que no se utilizó ninguna herramienta de IA para la conceptualización, traducción o redacción de este artículo.