

# Evaluation of handheld optical sensors and drone-acquired multispectral images for yield estimation

## Evaluación de sensores ópticos manuales e imágenes multiespectrales adquiridas con dron para estimación de rendimiento

Víctor Manuel Gordillo-Salinas<sup>1\*</sup>; Alondra Villeda-Monsalvo<sup>2</sup>;  
Juan Arista-Cortes<sup>1</sup>; Jorge Flores-Velázquez<sup>3</sup>

<sup>1</sup>Instituto Mexicano de Tecnología del Agua. Paseo Cuauhnáhuac núm. 8532, Progreso, Jiutepec, Morelos, C. P. 62550, MÉXICO.

<sup>2</sup>Grupo de Investigación & Evaluación Agrícola TECO S.A. de C.V. Calle Emiliano Zapata núm. 16, San Luis Huexotla, Texcoco, Estado de México, C. P. 56220, MÉXICO.

<sup>3</sup>Colegio de Postgraduados, Campus Montecillo. Carretera México-Texcoco km 36.5, Montecillo, Texcoco, Estado de México, C. P. 56230, MÉXICO.

\*Corresponding author: gordillo.victor@hotmail.com, tel. 55 69 64 65 53.

### Abstract

**Introduction:** Chlorophyll in wheat leaves is linked to grain yield, and measuring its reflectance allows predicting crop yield.

**Objective:** To evaluate the potential of GreenSeeker (GS) and SPAD502+ sensors, and spectral images acquired with an infrared camera fitted on an unmanned aerial vehicle (UAV) to estimate grain yield in wheat.

**Methodology:** Variable nitrogen concentrations were applied, and readings were taken with SPAD502+ and direct GS on wheat during the thickened sheath and heading phenological stages. Simultaneously, aerial images were captured with a multispectral camera to determine vegetation indices.

**Results:** The comparison between measured and estimated yields with optical sensors shows that GS presented the best fit, with a coefficient of determination ( $R^2$ ) of 0.86 in thickened sheaths. The fit with the green normalized difference vegetation index (GNDVI) was better in heading ( $R^2 = 0.89$ ).

**Limitations of the study:** Sensors with higher spectral resolution and earlier crop stages should be evaluated to estimate yield earlier.

**Originality:** The study shows the potential of optical sensors to estimate yield, thereby overcoming the time and economic resource limitations entailed in conventional methods.

**Conclusions:** GNDVI and GS are reliable, fast and non-destructive options to forecast wheat grain yield; however, UAVs allow scaling up crop monitoring and reducing the time to obtain field information.

### Resumen

**Introducción:** La clorofila de las hojas de trigo está vinculada con el rendimiento de grano, y medir su reflectancia permite predecir el rendimiento del cultivo.

**Objetivo:** Evaluar el potencial de los sensores GreenSeeker (GS) y SPAD502+, y de imágenes espectrales adquiridas con una cámara infrarroja transportada en un vehículo aéreo no tripulado (VANT) para estimar el rendimiento de grano en trigo.

**Metodología:** Se aplicaron concentraciones variables de nitrógeno, y se tomaron lecturas con SPAD502+ y GS directo en trigo durante las etapas fenológicas de vaina engrosada y espigado. Simultáneamente, se capturaron imágenes aéreas con una cámara multiespectral para determinar índices de vegetación.

**Resultados:** La comparación entre el rendimiento medido y el estimado con los sensores ópticos muestra que el GS presentó el mejor ajuste, con un coeficiente de determinación ( $R^2$ ) de 0.86 en vaina engrosada. El ajuste con el índice de vegetación de diferencias normalizadas del verde (GNDVI) fue mejor en espigado ( $R^2 = 0.89$ ).

**Limitaciones del estudio:** Se deben evaluar sensores con mayor resolución espectral y etapas más tempranas del cultivo para estimar el rendimiento con mayor antelación.

**Originalidad:** El estudio muestra el potencial de los sensores ópticos para estimar el rendimiento; con ello, se superan las limitaciones de tiempo y recurso económico que demandan los métodos convencionales.

**Conclusiones:** El GNDVI y el GS son opciones confiables, rápidas y no destructivas para pronosticar el rendimiento de grano de trigo; sin embargo, los VANTs permiten escalar el monitoreo de los cultivos y reducir los tiempos de obtención de la información de campo.

### Palabras clave:

índices de vegetación,  
GreenSeeker, SPAD502+,  
etapa fenológica, trigo.

## Introduction

Wheat ranks second among the main cereals consumed in Mexico, accounting for about 10 % of caloric consumption (U.S. Department of Agriculture - Foreign Agricultural Service [USDA-FAS], 2019). However, production costs have increased in recent years, with fertilization being the most expensive cultural activity, accounting for approximately 30 % of the total production cost. The balance between wheat price, yields and production costs generates little profit margin for the producer (Retes-López et al., 2020).

To determine whether a crop is economically profitable, it is essential to estimate the expected yield in order to identify and establish farming practices that favor production. This requires rapid and precise methods, as well as non-destructive techniques to manage resources, such as the application of nitrogen fertilization, on which the increase in yield depends (Guo et al., 2020; Qiao et al., 2022; Shibayama et al., 2012).

Yield is associated with leaf chlorophyll content; therefore, the use of optical sensors allows determining different crop parameters, such as biomass, canopy fraction or reflectance indices (such as the greenness index) (Yue et al., 2021), at various scales and different parts of the crop. The SPAD502+ (Minolta Ltd, Japan) is a commercial chlorophyll meter, and its use has shown a significant positive correlation with grain yield (Monostori et al., 2016); however, its ability to detect nitrogen status varies with the stage of crop development (Rahman et al., 2020). On the other hand, the GreenSeeker (GS) (Trimble®, USA) is an optical sensor that measures crop canopy reflectance. The use of this sensor has generated good results in estimating grain yield at different crop growth stages (Ali et al., 2020; Kaur et al., 2018; Yegül et al., 2020).

Technological progress has enabled the development of new optical sensors to indirectly estimate crop yields. These include sensors mounted on aerial devices, such as satellites, manned aircraft and, recently, unmanned aerial vehicles (UAVs), also known as drones. UAVs are affordable aerial platforms with several maneuverability advantages. Optical sensors are installed on these devices, which allow generating spectral information without direct contact with objects in the area of interest (Du & Noguchi, 2016; Saravia et al., 2023; Tsouros et al., 2019).

Cameras are optical sensors that are classified as multispectral, hyperspectral and thermal, and allow determining vegetation indices (VI). These indices have been used to indirectly determine agronomic variables such as yield, leaf chlorophyll content, biomass, leaf area index, crop height and canopy cover, among

## Introducción

El trigo ocupa el segundo lugar entre los principales cereales consumidos en México, al representar cerca del 10 % del consumo calórico (U.S. Department of Agriculture - Foreign Agricultural Service [USDA-FAS], 2019). No obstante, en los últimos años se han incrementado los costos de producción, siendo la fertilización la actividad cultural de mayor gasto, con aproximadamente 30 % del costo total de producción. El balance entre el precio del trigo, los rendimientos y los costos de producción genera poco margen de utilidad al productor (Retes-López et al., 2020).

Para determinar si el cultivo es rentable económicamente, es fundamental estimar el rendimiento esperado, con la finalidad de identificar y establecer prácticas agrícolas que favorezcan la producción. Para ello, se requieren métodos rápidos y precisos, así como técnicas no destructivas para gestionar los recursos, como la aplicación de fertilización nitrogenada, de la cual depende el incremento del rendimiento (Guo et al., 2020; Qiao et al., 2022; Shibayama et al., 2012).

El rendimiento está asociado al contenido de clorofila de las hojas; por ello, el uso de sensores ópticos permite determinar distintos parámetros de los cultivos, como biomasa, fracción de cubierta vegetal o índices de reflectancia (como el índice de verdor) (Yue et al., 2021), a varias escalas y diferentes partes del cultivo. El SPAD502+ (Minolta Ltd, Japón) es un medidor de clorofila comercial, y su uso ha demostrado una correlación positiva significativa con el rendimiento de grano (Monostori et al., 2016); sin embargo, su capacidad para detectar el estatus del nitrógeno varía con la etapa de desarrollo del cultivo (Rahman et al., 2020). Por otra parte, el GreenSeeker (GS) (Trimble®, EUA) es un sensor óptico que mide la reflectancia del dosel del cultivo. El uso de este sensor ha generado resultados importantes en la estimación del rendimiento de grano en diferentes etapas de crecimiento de un cultivo (Ali et al., 2020; Kaur et al., 2018; Yegül et al., 2020).

El avance tecnológico ha permitido el desarrollo de nuevos sensores ópticos para estimar, de manera indirecta, el rendimiento de los cultivos. Entre estos destacan los sensores montados en dispositivos aéreos, como los satélites, las aeronaves tripuladas y, recientemente, los vehículos aéreos no tripulados (VANTs), también conocidos como drones. Los VANTs son plataformas aéreas económicamente accesibles con diversas ventajas de maniobrabilidad. Sobre estos dispositivos se instalan sensores ópticos, los cuales permiten generar información espectral sin contacto directo con los objetos del área de interés (Du & Noguchi, 2016; Saravia et al., 2023; Tsouros et al., 2019).

others (dos Santos et al., 2021; Feng et al., 2020; Gilliot et al., 2021; Li et al., 2022).

Walsh et al. (2022) evaluated the accuracy of an optical sensor placed on a UAV to estimate the average yield of three wheat genotypes, and compared it with GS sensor readings. These authors report that GS explained up to 79 % of yield, and the normalized difference vegetative index (NDVI) derived from UAV images explained 67 % of this variable; they also reported a strong correlation between GS and UAV ( $R^2 = 85\%$ ).

Technology continues to evolve; therefore, the use of optical sensors under different climatic, nutritional and operating conditions should continue to be explored. Considering the above, this research aimed to evaluate the performance of the GS and SPAD502+ sensors, and of a multispectral camera mounted on a UAV to estimate the yield of a wheat crop under different nitrogen levels and at two phenological stages close to flowering (thickened sheath and heading).

## Materials and methods

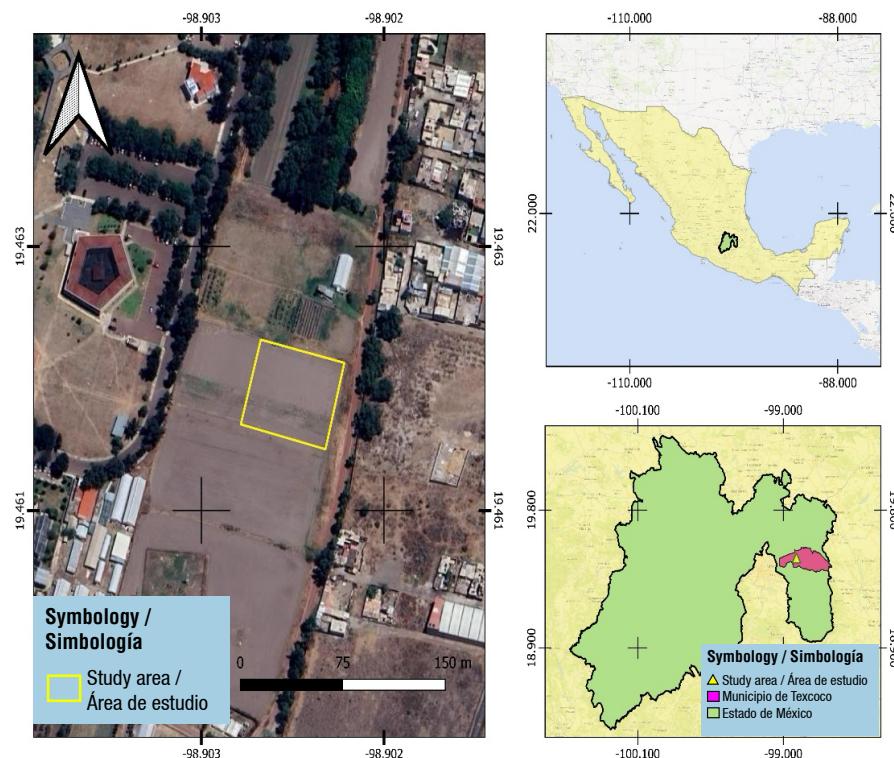
### Description of the experimental site

The experiment was established in the experimental field of the *Colegio de Postgrados Campus Montecillo* ( $19^{\circ} 27' 36.0''$  N and  $98^{\circ} 54' 00''$  W, at 2250 m a.s.l.) (Figure 1), characterized by a temperate climate

Las cámaras son sensores ópticos que se clasifican en multiespectrales, hiperespectrales y térmicas, y permiten determinar índices de vegetación (IV). Estos índices han sido utilizados para determinar, de manera indirecta, variables agronómicas como el rendimiento, el contenido de clorofila de la hoja, la biomasa, el índice de área foliar, la altura del cultivo y la cobertura del dosel, entre otras (dos Santos et al., 2021; Feng et al., 2020; Gilliot et al., 2021; Li et al., 2022).

Walsh et al. (2022) evaluaron la precisión de un sensor óptico colocado en un VANT para estimar el rendimiento promedio de tres genotipos de trigo, y lo compararon con lecturas del sensor GS. Estos autores mencionan que el GS explicó hasta un 79 % el rendimiento, y el índice normalizado de verdor (NDVI, por sus siglas en inglés) derivado de imágenes de un VANT explicó dicha variable en un 67 %; asimismo, reportaron una fuerte correlación entre el GS y el VANT ( $R^2 = 85\%$ ).

La tecnología sigue evolucionando; por ello, se debe continuar explorando el uso de sensores ópticos bajo diferentes condiciones climáticas, nutricionales y de operación. Considerando lo anterior, el objetivo de esta investigación fue evaluar el desempeño de los sensores GS y SPAD502+, y de una cámara multiespectral colocada en un VANT para estimar el rendimiento de un cultivo de trigo bajo diferentes niveles nitrógeno y en dos etapas fenológicas cercanas a la floración (vaina engrosada y espigamiento).



**Figure 1. Geographic location of the study area site.**

**Figura 1. Localización geográfica del sitio del área de estudio.**

with rainfall in summer and the dry season in winter [(Cwo)(w)b(i') (g)] (García, 2004), an average annual temperature of 15.2 °C and 650 mm of annual precipitation.

The Nana 2007 wheat variety was established in mid-February and harvested at the end of June 2019. This variety was released by the National Rainfed Wheat Program of the National Institute of Forestry, Agriculture and Livestock Research (INIFAP), and was obtained by hybridization and selection through the combination of mass methods and families (Villaseñor-Mir et al., 2014). Seed density was 100 kg·ha<sup>-1</sup>, and drip irrigation was applied. Plant care was carried out according to conventional practices in the area.

The experimental design was completely randomized with seven treatments (nitrogen dose [kg·ha<sup>-1</sup>]: T1 = 0, T2 = 40, T3 = 60, T4 = 80, T5 = 100, T6 = 140 and T7 = 180) and four replications (Figure 2). The experimental unit size was 4 × 10.5 m, which covered an area of 1600 m<sup>2</sup>. N was applied at two times: during sowing and at the final phenological stage of stem elongation.

#### Experimental data acquisition with ground-based optical sensors

At each phenological stage (thickened sheath and heading) a systematic sampling was carried out: three on one side, three in the center and three on the other side (Figure 3), resulting in nine readings for each experimental unit, both with GS and SPAD502+.

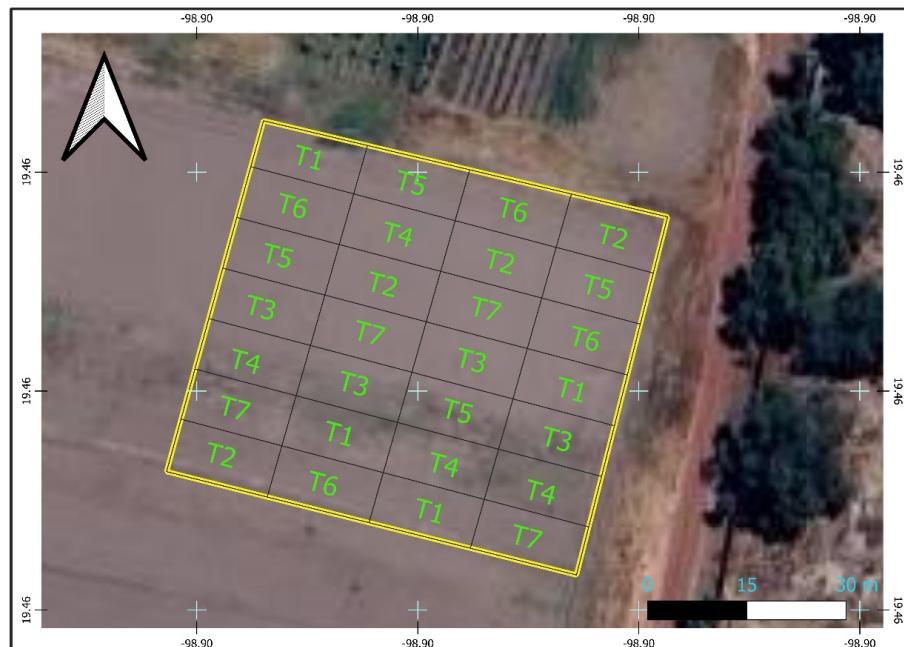
## Materiales y métodos

### Descripción del sitio experimental

El experimento se estableció en el campo experimental del Colegio de Postgraduados Campus Montecillo (19° 27' 36.0" N y 98° 54' 00" O, a 2250 m s. n. m.) (Figura 1), caracterizado por un clima templado con lluvias en verano y época seca en invierno [(Cwo)(w)b(i') (g)] (García, 2004), temperatura promedio anual de 15.2 °C y 650 mm de precipitación anual.

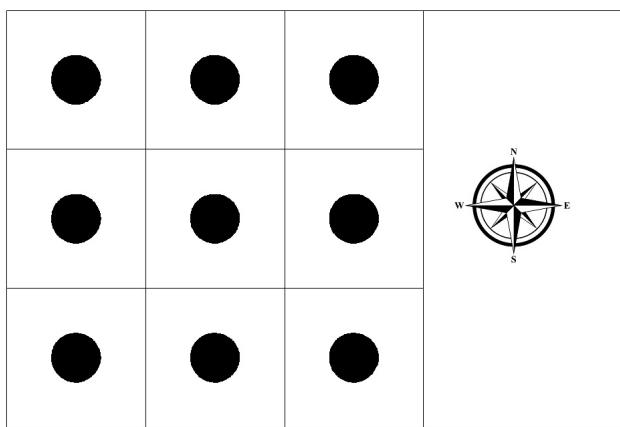
El cultivo de trigo variedad Nana 2007 se estableció a mediados de febrero y se cosechó a finales de junio de 2019. Esta variedad la liberó el Programa Nacional de Trigo de Temporal del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP), se obtuvo por hibridación y selección mediante la combinación de los métodos y familias masivas (Villaseñor-Mir et al., 2014). La densidad de semilla fue de 100 kg·ha<sup>-1</sup>, y el riego se suministró por goteo. Los cuidados de la planta se realizaron conforme las prácticas convencionales de la zona.

El diseño experimental fue completamente al azar con siete tratamientos (dosis de nitrógeno [kg·ha<sup>-1</sup>]: T1 = 0, T2 = 40, T3 = 60, T4 = 80, T5 = 100, T6 = 140 y T7 = 180) y cuatro repeticiones (Figura 2). El tamaño de la unidad experimental fue de 4 × 10.5 m, lo cual abarcó una superficie de 1600 m<sup>2</sup>. El N se aplicó en dos momentos: durante la siembra y en la etapa fenológica de final de elongación de tallo.



**Figure 2. Spatial arrangement of nitrogen treatments.**

**Figura 2. Arreglo espacial de los tratamientos de nitrógeno.**



**Figure 3. Systematic sampling design for GreenSeeker and SPAD502+ sensors.**

**Figura 3. Diseño sistemático del muestreo con sensores GreenSeeker y SPAD502+.**

Measurements with the GS sensor were taken, on average, at 1 m above the crop canopy (Figure 4a), whereas the SPAD502+ readings were taken at a midpoint of the fully developed flag leaf (Figure 4b) as indicated by Yue et al. (2020). The recorded readings were averaged to determine the representative value of the experimental unit and, subsequently, the average value of each treatment was determined; this was done for each data set obtained with each sensor.

#### Multispectral image acquisition and processing

The flight schedule and dates were synchronized with the samplings carried out with the GS and SPAD502+ sensors. The UAV (multirotor 3DR X8+, 3D Robotics, USA) was fitted with a multispectral camera (Canon S110 NIR, bands: blue [400–495 nm], green [490–550 nm], near-infrared [680–760 nm]; Haghigattalab et al., 2016) to obtain images at 120 m above ground level, resulting in a spatial resolution of 3 cm·pixel<sup>-1</sup>. Flights were conducted at midday to avoid shadowing in the collected images. The sky was clear during all sessions.

The images were processed in Pix4D software (Pix4D SA, Switzerland), and orthomosaics of the surface reflectance were obtained for each channel of the multispectral camera, as well as a point cloud and a digital surface model. The processing of the imagery derived from UAVs is mainly based on the combination of photogrammetric and computer vision algorithms (Remondino et al., 2014). Berra and Peppa (2020) state that image processing can be summarized in three phases: 1) sparse point cloud reconstruction, 2) georeferencing and 3) dense point cloud reconstruction.

High-resolution images collected from UAVs contain too much surface information, which requires equipment with great ability to extract and analyze the information (Ye et al., 2023). The images may contain vegetation, shadows, soil and weeds, among

#### Adquisición de datos experimentales con los sensores ópticos terrestres

En cada etapa fenológica (vaina engrosada y espigado) se realizó un muestreo de manera sistemática: tres en un costado, tres al centro y tres en el otro costado (Figura 3), con lo cual se obtuvieron nueve lecturas de cada unidad experimental, tanto con GS como con SPAD502+.

Las mediciones con el sensor GS se realizaron, en promedio, a 1 m de altura sobre el dosel del cultivo (Figura 4a). Por su parte, las lecturas con SPAD502+ se llevaron a cabo en un punto medio de la hoja bandera completamente desarrollada (Figura 4b) como lo indican Yue et al. (2020). Las lecturas registradas se promediaron para determinar el valor representativo de la unidad experimental y, posteriormente, se determinó el valor promedio de cada tratamiento; esto se realizó para cada conjunto de datos obtenido con cada sensor.

#### Adquisición y procesamiento de imágenes multiespectrales

El horario y las fechas de los vuelos se sincronizaron con los muestreos realizados con los sensores GS y SPAD502+. Al VANT (multirotor 3DR X8+, 3D Robotics, EUA) se le instaló una cámara multiespectral (Canon S110 NIR, bandas: azul [400–495 nm], verde [490–550 nm], infrarrojo cercano [680–760 nm]; Haghigattalab et al., 2016) para obtener imágenes a 120 m sobre el nivel del suelo, con lo cual se obtuvo una resolución espacial de 3 cm·pixel<sup>-1</sup>. Los vuelos se realizaron a medio día para evitar el sombreado en las imágenes colectadas. El cielo estuvo despejado en todas las sesiones.

Las imágenes se procesaron en el programa Pix4D (Pix4D SA, Suiza), y se obtuvieron ortomosaicos de la



**Figure 4. Measurements made with the sensors: a) GreenSeeker and b) SPAD502+.**

**Figura 4. Mediciones realizadas con los sensores: a) GreenSeeker y b) SPAD502+.**

other objects; therefore, it is necessary to segregate the information to analyze exclusively the object of interest. One method that allows this action is object-based image analysis (OBIA), which uses a set of pixels with similar characteristics, based on the texture, shape, spatial structure and other multidimensional characteristics of adjacent pixels (Filippi et al., 2022).

In the present study, the multiresolution segmentation algorithm included in eCognition software (Trimble Inc., USA) was used to classify vegetation pixels into objects. This tool is intended to reduce the bias contributed by other objects to the VI values for each experimental unit, especially in treatments with low nitrogen doses, which have a less developed canopy and do not have full cover. This pixel segregation has been shown to improve the accuracy of VI estimation by minimizing the influence of the soil (Duan et al., 2017), reaching accuracies of up to 90 % in the classification of herbaceous crop vegetation (Torres-Sánchez et al., 2015). At the end of the analysis, eCognition delivers the objects that it classified as vegetation in the orthoimage in vector format.

#### Vegetation indices (VI)

It is known that VIs are obtained from plant reflectance using the electromagnetic spectrum; however, in order to relate them to vigor and productivity, it is necessary to understand the optical properties of the leaves, mainly the role of chlorophyll, carotenoids and xanthophylls, as well as the mesophyll cells in light reflectance and absorbance (Taddeo et al., 2019).

The selection of the spectral vegetation index should be made from the temporal spectral variability approach, so that it can be correlated with the physiological variable of interest, such as grain yield. This variability

reflectancia de la superficie para cada canal de la cámara multiespectral, así como una nube puntos y un modelo digital de superficie. El procesamiento de las imágenes derivadas de VANTs se basa, principalmente, en la combinación de algoritmos fotogramétricos y de visión por computadora (Remondino et al., 2014). Berra y Peppa (2020) mencionan que el procesamiento de imágenes se puede resumir en tres fases: 1) reconstrucción de la nube de puntos dispersa, 2) georreferenciación y 3) reconstrucción de la nube de puntos densa.

Las imágenes de alta resolución colectadas desde los VANTs contienen demasiada información de la superficie, por lo cual se requiere un equipo con gran capacidad para extraer y analizar la información (Ye et al., 2023). Las imágenes pueden contener: vegetación, sombras, suelo y malezas, entre otros objetos; por ello, es necesario segregar la información para analizar exclusivamente el objeto de interés. Un método que permite realizar esta acción es el análisis de imágenes orientadas a objetos (OBIA, por sus siglas en inglés), el cual utiliza un conjunto de píxeles con características similares, basándose en la textura, forma, estructura espacial y otras características multidimensionales de los píxeles adyacentes (Filippi et al., 2022).

En el presente estudio, se utilizó el algoritmo de segmentación de múltiples resoluciones incluido en el programa eCognition (Trimble Inc., EUA) para clasificar los píxeles de la vegetación en objetos. Con dicha herramienta se pretende disminuir el sesgo que aportan otros objetos a los valores de los IV para cada unidad experimental, especialmente en los tratamientos con bajas dosis de nitrógeno, los cuales presentan un dosel menos desarrollado y no tienen cobertura total. Se ha demostrado que esta segregación de píxeles mejora la precisión de la estimación de los IV al minimizar la influencia del suelo (Duan et al., 2017),

occurs in wheat plants with discrete flowers, which turn green at the beginning of the reproductive stages, and yellow, or even brown, at the maturation stage (Sulik & Long, 2016).

This research used the green normalized difference vegetation index (GNDVI; Gitelson et al., 1996) and the blue normalized difference vegetation index (BNDVI; Wang et al., 2007), which were calculated as follows:

$$GNDVI = \frac{NIR-G}{NIR+G} \quad (1)$$

$$BNDVI = \frac{NIR-B}{NIR+B} \quad (2)$$

where *NIR* is the near-infrared wavelength, *G* is the green wavelength and *B* is the blue wavelength.

The selection of these indices was made mainly based on the spectral channels available in the multispectral camera (green, blue and near infrared). The GNDVI performs well in predicting yield for different crops (Wahab et al., 2018; Jewan et al., 2021; Yang et al., 2022); in addition, Gitelson et al. (1996) state that the green electromagnetic region has shown higher sensitivity to a wider range of chlorophyll concentration than the red region. As for the BNDVI, it requires the blue of the visible spectrum to monitor areas sensitive to chlorophyll content; likewise, good results in yield estimation have been obtained with this index (Lukas et al., 2022). However, Zeng et al. (2021) evaluated different indices at different phenological stages of wheat and observed that indices including the blue band of the spectrum have a low correlation with yield. In particular, at the flowering stage they obtained a value of  $R^2 = 0.7$  (average of all indices with blue band).

With the information from each VI, a new image (raster) was generated for the two phenological stages using the map algebra technique, which allows combining spectral bands from mathematical operators, since it treats the spatial data layers as variables (Mali et al., 2005). Finally, the average value of the BNDVI and GNDVI was estimated for each experimental unit. To do this, the vector layer classified as vegetation by eCognition and the vector layer of the perimeter of the experimental units in the Qgis program (OSGeo Foundation, USA) were used. Subsequently, the average of each treatment was determined.

### Grain yield measurement

At the end of the wheat growth cycle, grain yield was determined by sampling with a  $1.0 \times 1.0$  m frame, which was randomly dropped within each experimental unit. The plants remaining within the frame were counted, and the grain was extracted from these plants and weighed on a precision balance to obtain the weight

al alcanzar precisiones de hasta 90 % en la clasificación de vegetación de cultivos herbáceos (Torres-Sánchez et al., 2015). Al finalizar el análisis, eCognition entrega los objetos que clasificó como vegetación en la ortoimagen en formato vectorial.

### Índices de vegetación (IV)

Se sabe que los IV se obtienen a partir de la reflectancia de las plantas mediante el espectro electromagnético; sin embargo, para poder relacionarlos con el vigor y la productividad, es necesario entender las propiedades ópticas de las hojas, principalmente el papel de la clorofila, los carotenoides y las xantofilas, así como de las células del mesófilo en la reflectancia y absorbancia de la luz (Taddeo et al., 2019).

La selección del índice espectral de vegetación se debe hacer desde el enfoque de variabilidad espectral temporal, para que se pueda correlacionar con la variable fisiológica de interés, como el rendimiento de grano. Esta variabilidad se presenta en plantas de trigo con flores discretas, las cuales se vuelven verdes al inicio de las etapas reproductivas, y amarillas, o incluso marrones, en la etapa de maduración (Sulik & Long, 2016).

En esta investigación se usaron el índice de vegetación de diferencias normalizadas del verde (GNDVI, por sus siglas en inglés; Gitelson et al., 1996) y el índice de vegetación de diferencias normalizadas del azul (BNDVI, por sus siglas en inglés; Wang et al., 2007), los cuales se calcularon de la siguiente manera:

$$GNDVI = \frac{NIR-G}{NIR+G} \quad (1)$$

$$BNDVI = \frac{NIR-B}{NIR+B} \quad (2)$$

donde *NIR* es la longitud de onda del infrarrojo cercano, *G* es la longitud de onda del verde y *B* es la longitud de onda del azul.

La selección de estos índices se realizó, principalmente, con base en los canales espectrales disponibles en la cámara multiespectral (verde, azul e infrarrojo cercano). El GNDVI presenta un buen desempeño en la predicción del rendimiento para distintos cultivos (Wahab et al., 2018; Jewan et al., 2021; Yang et al., 2022); además, Gitelson et al. (1996) mencionan que la región electromagnética del verde ha mostrado mayor sensibilidad a un rango más amplio de concentración de clorofila que la región del rojo. Por su parte, el BNDVI requiere el azul del espectro del visible para monitorear áreas sensibles al contenido de clorofila; asimismo, con este índice se han obtenido buenos resultados en la estimación del rendimiento (Lukas et al., 2022). No obstante, Zeng et al. (2021) evaluaron diferentes índices en distintas etapas fenológicas del trigo y observaron

per m<sup>2</sup>. The average for each treatment was obtained from the values of the corresponding replicates.

### Data analysis and relationship of sensor values with yield

Data obtained with the multispectral camera (BNDVI and GNDVI), the GS and the SPAD502+, as well as the grain yield values, were subjected to a process of eliminating outliers using the interquartile range technique. Outliers have a significant influence on the arithmetic mean, and can generate averages that are not representative of the experimental units.

The average values of BNDVI, GNDVI, GS and SPAD502+ of each treatment were correlated with the grain yield data by means of a regression analysis performed with R studio 4.2.2 software and the ggplot2 tool for generating graphs. Two regression models (linear and polynomial) were applied to determine the goodness of fit of each sensor at the two phenological stages. The coefficient of determination ( $R^2$ ) was also estimated to determine the prediction quality of the models.

## Results and discussion

### Ground-based optical sensor measurements and vegetation indices

Table 1 shows the average yield per treatment, as well as the values obtained with the sensors and VIs at the thickened sheath phenological stage.

Table 2 shows the average yield of each treatment, as well as the values obtained with the sensors and VIs at the heading stage.

que los índices que incluyen la banda azul del espectro tienen baja correlación con el rendimiento. En particular, en la etapa de floración obtuvieron un valor de  $R^2 = 0.7$  (promedio de todos los índices con banda azul).

Con la información de cada IV se generó una nueva imagen (raster) para las dos etapas fenológicas mediante la técnica álgebra de mapas, la cual permite combinar bandas espectrales a partir de operadores matemáticos, ya que trata a las capas de datos espaciales como variables (Mali et al., 2005). Por último, se estimó el valor promedio del BNDVI y el GNDVI para cada unidad experimental. Para ello, se usó la capa vectorial clasificada como vegetación por el eCognition y la capa vectorial del perímetro de las unidades experimentales en el programa Qgis (fundación OSGeo, EUA). Posteriormente, se determinó el promedio de cada tratamiento.

### Medición del rendimiento de grano

Al final del ciclo de cultivo del trigo, se determinó el rendimiento de grano mediante un muestreo realizado con un marco de 1.0 × 1.0 m, el cual se lanzó al azar dentro de cada unidad experimental. Se contaron las plantas que quedaron dentro del marco, se extrajo el grano de estas plantas y se pesó en una balanza de precisión para obtener el peso por cada m<sup>2</sup>. El promedio de cada tratamiento se obtuvo a partir de los valores de las repeticiones correspondientes.

### Análisis de datos y relación de los valores de los sensores con el rendimiento

Los datos obtenidos con la cámara multiespectral (BNDVI y GNDVI), el GS y el SPAD502+, así como los valores de rendimiento de grano, se sometieron a un

**Table 1. Average yield per treatment, and values obtained with the sensors (GreenSeeker and SPAD502+) and vegetation indices (BNDVI and GNDVI) at the thickened sheath stage.**

**Cuadro 1. Rendimiento promedio por tratamiento, y valores obtenidos con los sensores (GreenSeeker y SPAD502+) y los índices de vegetación (BNDVI y GNDVI) en la etapa de vaina engrosada.**

Treatment/ Tratamiento	Yield (g·m <sup>-2</sup> )/ Rendimiento (g·m <sup>-2</sup> )	SPAD502+	GreenSeeker	BNDVI	GNDVI
T1	512	43.6	0.63	1.40	0.60
T2	479	44.9	0.68	1.44	0.61
T3	538	45.9	0.70	1.63	0.71
T4	535	45.5	0.71	1.51	0.65
T5	522	47.9	0.71	1.57	0.67
T6	595	48.5	0.75	1.56	0.68
T7	639	47.8	0.79	1.70	0.72

BNDVI = blue normalized difference vegetation index; GNDVI = green normalized difference vegetation index.

BNDVI = índice de vegetación de diferencias normalizadas del azul; GNDVI = índice de vegetación de diferencias normalizadas del verde.

Table 3 shows the coefficients of determination obtained with the models (linear and polynomial) when comparing grain yield with the values obtained with the sensors and VIs, and it can be observed that the second-degree polynomial model better explains the yield variable, by presenting higher  $R^2$  values.

Second-degree polynomial models have been used to evaluate the potential of optical sensors in grain yield estimation at different stages of wheat crop development (Holzman et al., 2014; Zhang et al., 2019). On the other hand, Hassan et al. (2019), Zeng et al. (2021) and Walsh et al. (2022) obtained a good correlation when using a linear model to estimate yield at various stages of crop development (from the tillering stage to harvest). The differences between the present work and those mentioned above could

processo de eliminación de datos atípicos (también llamados extremos o *outliers*) mediante la técnica de rango intercuartil. Los datos atípicos tienen una influencia significativa en la media aritmética, y pueden generar promedios no representativos de las unidades experimentales.

Los valores promedio de BNDVI, GNDVI, GS y SPAD502+ de cada tratamiento se correlacionaron con los datos de rendimiento de grano mediante un análisis de regresión realizado con el programa R estudio 4.2.2 y la herramienta ggplot2 para la generación de los gráficos. Se aplicaron dos modelos de regresión (lineal y polinómica) para conocer la bondad de ajuste de cada sensor en las dos etapas fenológicas. Asimismo, se estimó el coeficiente de determinación ( $R^2$ ) para conocer la calidad de predicción de los modelos.

**Table 2. Average yield per treatment, and values obtained with the sensors (GreenSeeker and SPAD502+) and vegetation indices (BNDVI and GNDVI) at the heading stage.**

**Cuadro 2. Rendimiento promedio por tratamiento, y valores obtenidos con los sensores (GreenSeeker y SPAD502+) y los índices de vegetación (BNDVI y GNDVI) en la etapa de espigado.**

Treatment / Tratamiento	Yield (g·m <sup>-2</sup> ) / Rendimiento (g·m <sup>-2</sup> )	SPAD502+	GreenSeeker	BNDVI	GNDVI
T1	512.5	42.5	0.59	2.06	0.83
T2	479.0	44.6	0.62	2.07	0.83
T3	538.5	44.3	0.68	2.11	0.87
T4	535.5	45.1	0.66	2.16	0.89
T5	522.5	47.8	0.70	2.15	0.89
T6	595.0	48.3	0.72	2.20	0.91
T7	639.0	47.9	0.74	2.18	0.92

BNDVI = blue normalized difference vegetation index; GNDVI = green normalized difference vegetation index.

BNDVI = índice de vegetación de diferencias normalizadas del azul; GNDVI = índice de vegetación de diferencias normalizadas del verde.

**Table 3. Coefficients of determination of the comparison of grain yield with sensor measurements and vegetation indices at two phenological stages.**

**Cuadro 3. Coeficientes de determinación de la comparación del rendimiento de grano con las mediciones de los sensores y los índices de vegetación en dos etapas fenológicas.**

Sensor	Thickened sheath/Vaina engrosada		Heading/Espigado	
	Linear/Lineal	Polynomial/Polinómica	Linear/Lineal	Polynomial/Polinómica
SPAD 502+	0.4844	0.5051	0.4455	0.5081
GS	0.729	0.8678	0.6921	0.8713
BNDVI	0.6141	0.6647	0.6301	0.6652
GNDVI	0.5821	0.6172	0.7318	0.8932

BNDVI = blue normalized difference vegetation index; GNDVI = green normalized difference vegetation index.

BNDVI = índice de vegetación de diferencias normalizadas del azul; GNDVI = índice de vegetación de diferencias normalizadas del verde.

be due to different factors, such as crop variety, plant density, irrigation, nutrition, climate and even the type of sensor (Zhang et al., 2019).

Figure 5 shows a positive trend when comparing the values obtained with the sensors and the yield for the different treatments at the thickened sheath phenological stage; that is, the higher the value recorded by the sensors, the higher the yield. A similar trend was observed between the levels of nitrogen applied and yield.

The comparison of the sensor values and yield for the different nitrogen treatments during the heading stage is shown in Figure 6.

GS showed the best performance ( $R^2 = 0.8678$ ) at the thickened sheath stage, while at the heading stage the best yield prediction was obtained with GNDVI,

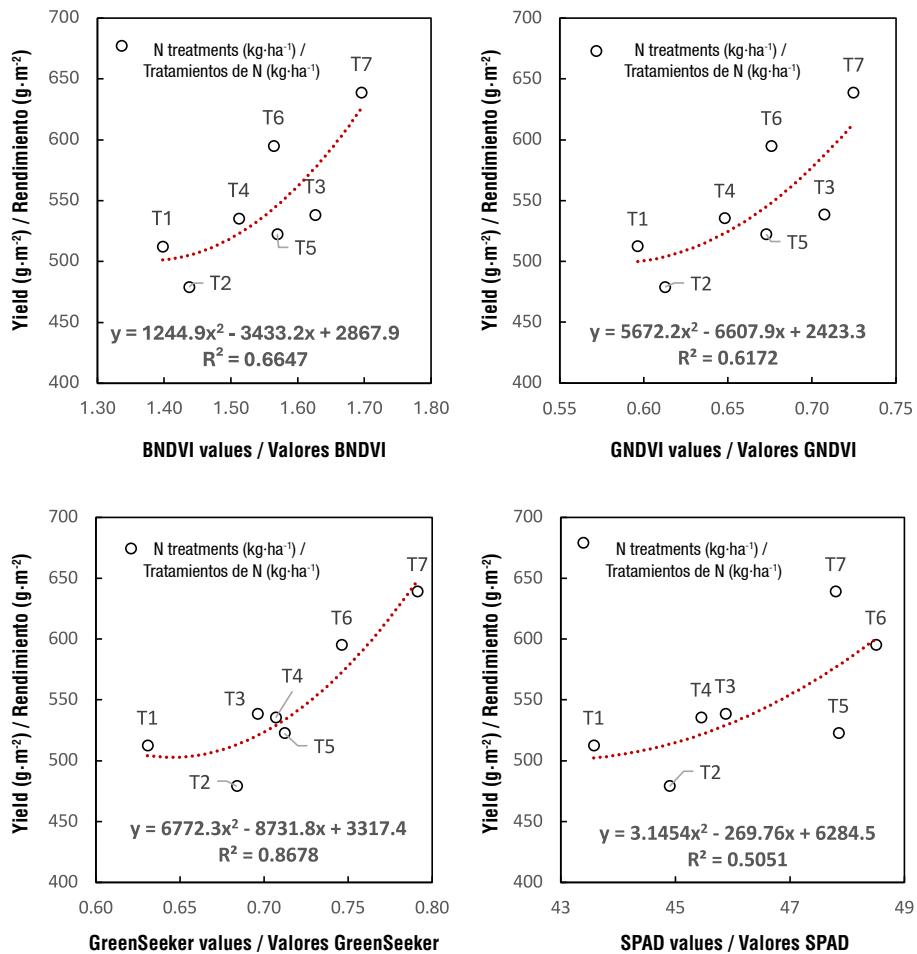
## Resultados y discusión

### Mediciones de los sensores ópticos terrestres e índices de vegetación

En el Cuadro 1 se muestra el rendimiento promedio por tratamiento, así como los valores obtenidos con los sensores y los IV en la etapa fenológica de vaina engrosada.

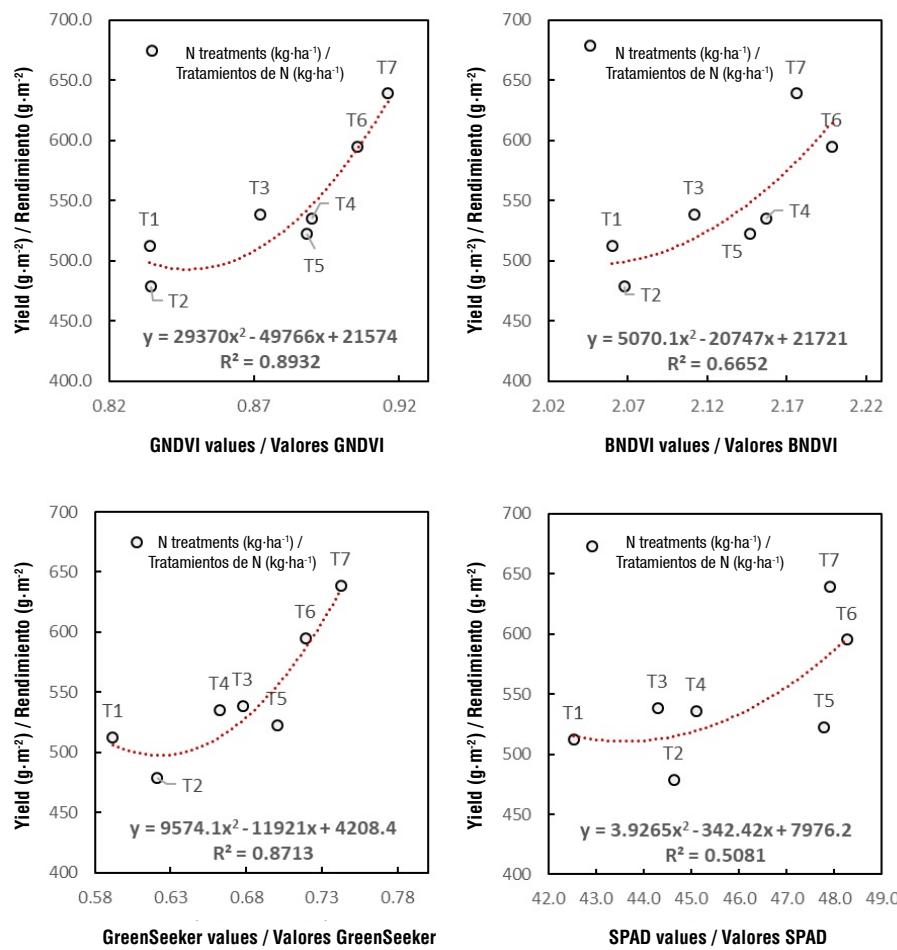
El Cuadro 2 presenta el rendimiento promedio de cada tratamiento, así como los valores obtenidos con los sensores y los IV en la etapa de espigado.

El Cuadro 3 muestra los coeficientes de determinación obtenidos con los modelos (lineales y polinómicos) al comparar el rendimiento de grano con los valores obtenidos con los sensores y los IV, y se puede observar que el modelo polinómico de segundo grado explica



**Figure 5. Relationship between yield and sensor readings at the thickened sheath phenological stage for the different nitrogen treatments.**

**Figura 5. Relación entre el rendimiento y las lecturas obtenidas con los sensores en la etapa fenológica de vaina engrosada para los distintos tratamientos de nitrógeno.**



**Figure 6. Relationship between yield and sensor readings at the heading phenological stage for the different nitrogen treatments.**

**Figura 6. Relación entre el rendimiento y las lecturas obtenidas con los sensores en la etapa fenológica de espigado para los distintos tratamientos de nitrógeno.**

followed by GS ( $R^2$  of 0.8713 and 0.8932, respectively). The SPAD502+ sensor had the lowest performance at both phenological stages, with an  $R^2$  around.

The results obtained coincide with those reported by Walsh et al. (2022), who observed that the GS sensor and the NDVI (derived from images from a multispectral camera mounted onto a UAV) perform better in yield estimation than the SPAD502+, which measures point readings on the leaf. The differences observed between the sensors may be due to the N concentration in the leaves (Cartelat et al., 2005) and the crop canopy, as it is not homogeneous (Eichelmann et al., 2005). Monostori et al. (2016) recommend calibrating the SPAD502+ sensor values for each variety and crop type, which could improve the accuracy of yield estimates.

The GS performance results agree with those reported by Zhang et al. (2019), who used this sensor to analyze the wheat crop canopy during the stages after full

mejor la variable rendimiento, al presentar valores de  $R^2$  superiores.

Los modelos polinómicos de segundo grado han sido empleados para evaluar el potencial de sensores ópticos en la estimación de rendimiento de grano en diferentes fases de desarrollo del cultivo de trigo (Holzman et al., 2014; Zhang et al., 2019). Por otra parte, Hassan et al. (2019), Zeng et al. (2021) y Walsh et al. (2022) obtuvieron una buena correlación al emplear un modelo lineal para estimar el rendimiento en varias etapas de desarrollo del cultivo (desde la etapa de macollamiento hasta la cosecha). Las diferencias del presente trabajo con los mencionados anteriormente se podrían deber a diferentes factores, como variedad del cultivo, densidad de planta, riego, nutrición, clima e, incluso, el tipo de sensor (Zhang et al., 2019).

En la Figura 5 se puede observar una tendencia positiva al comparar los valores obtenidos con los sensores y

cover (stages 8 to 10 on the Feekes scale), and observed high correlations with yield ( $R^2 = 0.9$ ). Similarly, Zeng et al. (2021) obtained reliable accuracy when using the GNDVI to estimate yield at various stages of crop development, from thickened sheath to grain filling, which coincides with the findings in the present work.

## Conclusions

Due to the great diversity of factors that influence the signal received by the sensors, more variables must be considered to develop the models, so that they can be representative of different crop conditions.

The use of indices, such as the GNDVI, has the potential to develop reliable models for yield prediction, since they detect the variation in the optical characteristics of the wheat crop. The use of spectral images obtained from cameras mounted onto UAVs allows obtaining coefficients of determination comparable to those achieved with the GS and SPAD502+. The advantage of using UAVs is that a larger area can be covered in less time, which is why they can be recommended as a viable alternative to replace the GS and SPAD502+. In this sense, the methodological proposal used in this work is a reliable alternative for acquiring images using UAVs at field scale; however, its effectiveness should be evaluated on a larger scale and with other crops to strengthen the results.

## Acknowledgments

The authors thank the *Consejo Nacional de Humanidades, Ciencias y Tecnologías* (CONAHCYT) for the postgraduate scholarship, the *Colegio de Posgraduados* for the support provided during the experimental phase, and the *Instituto Mexicano de Tecnología del Agua* (IMTA) for the assistance given in the writing of the article.

*End of English version*

## References / Referencias

- Ali, A. M., Ibrahim, S. M., & Bijay-Singh. (2020). Wheat grain yield and nitrogen uptake prediction using atLeaf and GreenSeeker portable optical sensors at jointing growth stage. *Information Processing in Agriculture*, 7(3), 375-383. <https://doi.org/10.1016/j.inpa.2019.09.008>
- Berra, E. F., & Peppa, M. V. (2020). Advances and challenges of UAV SFM MVS photogrammetry and remote sensing: short review. *IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)*. <https://doi.org/10.1109/LAGIRS48042.2020.9285975>
- Cartelat, A., Cerovic, Z. G., Goulas, Y., Meyer, S., Lelarge, C., Prioul, J. L., Barbottin, A., Jeuffroy, M. H., Gate, P., & Agati, G. (2005). Optically assessed contents of

el rendimiento para los distintos tratamientos en la etapa fenológica de vaina engrosada; es decir, a mayor valor registrado por los sensores mayor rendimiento. Una tendencia similar se observó entre los niveles de nitrógeno aplicado y el rendimiento.

La comparación de los valores obtenidos con los sensores y el rendimiento para los distintos tratamientos de nitrógeno durante la etapa de espigado se muestra en la Figura 6.

El GS mostró el mejor desempeño ( $R^2 = 0.8678$ ) en la etapa de vaina engrosada, mientras que en la etapa de espigado, la mejor predicción del rendimiento se tuvo con el GNDVI, seguido del GS ( $R^2$  de 0.8713 y 0.8932, respectivamente). El sensor SPAD502+ presentó el menor desempeño en ambas etapas fenológicas, con un  $R^2$  alrededor de 0.5.

Los resultados obtenidos coinciden con los reportados por Walsh et al. (2022), quienes observaron que el sensor GS y el NDVI (derivado de imágenes de una cámara multiespectral colocada en un VANT) tienen mejor desempeño en la estimación de rendimiento que el SPAD502+, el cual mide lecturas puntuales en la hoja. Las diferencias observadas entre los sensores se pueden deber a la concentración de N en las hojas (Cartelat et al., 2005) y el dosel del cultivo, ya que no es homogénea (Eichelmann et al., 2005). Monostori et al. (2016) recomiendan calibrar los valores del sensor SPAD502+ para cada variedad y tipo de cultivo, con lo cual se podría mejorar la precisión de las estimaciones de rendimiento.

Los resultados del desempeño del GS coinciden con lo reportado por Zhang et al. (2019), quienes utilizaron este sensor para analizar el dosel del cultivo de trigo durante las etapas posteriores a la cobertura total (etapas 8 a 10 en la escala de Feekes), y observaron altas correlaciones con el rendimiento ( $R^2 = 0.9$ ). Del mismo modo, Zeng et al. (2021) obtuvieron una precisión confiable al usar GNDVI para estimar el rendimiento en varias etapas de desarrollo del cultivo, desde vaina engrosada hasta llenado de grano, lo cual coincide con lo encontrado en el presente trabajo.

## Conclusiones

Debido a la gran diversidad de factores que influyen en la señal que reciben los sensores, se deben considerar más variables para desarrollar los modelos; esto para que puedan ser representativos a distintas condiciones de los cultivos.

El uso de índices, como el GNDVI, tiene potencial para desarrollar modelos confiables para la predicción de rendimiento, ya que estos detectan la variación

- leaf polyphenolics and chlorophyll as indicators of nitrogen deficiency in wheat (*Triticum aestivum* L.). *Field Crops Research*, 91, 35-49. <https://doi.org/10.1016/j.fcr.2004.05.002>
- dos Santos, R. A., Filgueiras, R., Mantovani, E. C., Fernandes-Filho, E. I., Almeida, T. S., Venancio, L. P., & Barbosa-da-Silva, A. C. (2021). Surface reflectance calculation and predictive models of biophysical parameters of maize crop from RG-NIR sensor on board a UAV. *Precision Agriculture* 22, 1535-1558. <https://doi.org/10.1007/s11119-021-09795-x>
- Du, M., & Noguchi, N. (2016). Multi-temporal monitoring of wheat growth through correlation analysis of satellite images, unmanned aerial vehicle images with ground variable. *IFAC-PapersOnLine*, 49(16), 5-9. <https://doi.org/10.1016/j.ifacol.2016.10.002>
- Duan, T., Chapman, S. C., Guo, Y., & Zheng, B. (2017). Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. *Field Crops Research*, 210, 71-80. <https://doi.org/10.1016/j.fcr.2017.05.025>
- Eichelmann, H., Oja, V., Rasulov, B., Padu, E., Bichele, I., Pettai, H., Mänd, P.; Kull, O., & Laisk, A. (2005). Adjustment of leaf photosynthesis to shade in a natural canopy: Reallocation of nitrogen. *Plant, Cell & Environment*, 28, 389-401. <https://doi.org/10.1111/j.1365-3040.2004.01275.x>
- Feng, A., Zhou, J., Vories, E. D., Sudduth, K. A., & Zhang, M. (2020). Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosystems Engineering*, 193, 101-114, <https://doi.org/10.1016/j.biosystemseng.2020.02.014>
- Filippi, A. M., Güneralp, İ., Castillo, C. R., Ma, A., Paulus, G., & Anders, K. H. (2022). Comparison of image endmember-and object-based classification of very-high-spatial-resolution unmanned aircraft system (UAS) narrow-band images for mapping riparian forests and other land covers. *Land*, 11(2), 246. <https://doi.org/10.3390/land11020246>
- García, E. (2004). *Modificaciones al sistema de clasificación climática de Köppen*. Universidad Nacional Autónoma de México
- Gilliot, J. M., Michelin, J., Hadjard, D., & Houot, S. (2021). An accurate method for predicting spatial variability of maize yield from UAV-based plant height estimation: a tool for monitoring agronomic field experiments. *Precision Agriculture*, 22, 897-921. <https://doi.org/10.1007/s11119-020-09764-w>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, 58(3), 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Guo, Y., Wang, H., Wu, Z., Wang, S., Sun, H., Senthilnath, J., Wang, J., Bryant, C. R., & Fu, Y. (2020). Modified red blue vegetation index for chlorophyll estimation and yield prediction of maize from visible images captured by UAV. *Sensors*, 20(18), 1-16. <https://doi.org/10.3390/s20185055>

de las características ópticas del cultivo de trigo. El uso de imágenes espectrales obtenidas de cámaras transportadas en VANTs permite obtener coeficientes de determinación comparables a los alcanzados con el GS y el SPAD502+. La ventaja de usar VANTs es que se puede abarcar una mayor superficie en menos tiempo, por lo cual se pueden recomendar como una alternativa viable para reemplazar el GS y el SPAD502+. En este sentido, la propuesta metodológica empleada en este trabajo es una alternativa confiable para adquirir imágenes con el uso de VANTs a escala de campo; sin embargo, se debe evaluar su efectividad a mayor escala y con otros cultivos para robustecer los resultados.

## Agradecimientos

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por la beca de posgrado, al Colegio de Posgraduados por el apoyo brindado en la fase de experimentación y al Instituto Mexicano de Tecnología del Agua (IMTA) por las facilidades concedidas en la escritura del artículo.

*Fin de la versión en español*

- Haghhighattalab, A., González Pérez, L., Mondal, S., Singh, D., Schinstock, D., Rutkoski, J., Ortiz-Monasterio, I., Singh, R. P., Goodin, D., & Poland, J. (2016). Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. *Plant Methods*, 12(1), 1-15. <https://doi.org/10.1186/s13007-016-0134-6>
- Hassan, M. A., Yang, M., Rasheed, A., Yang, G., Reynolds, M., Xia, X., Xiao, Y., & He, Z. (2019). A rapid monitoring of NDVI across the wheat growth cycle for grain yield prediction using a multi-spectral UAV platform, *Plant Science*, 282, 95-103. <https://doi.org/10.1016/j.plantsci.2018.10.022>
- Holzman, M. E., Rivas, R., & Piccolo, M. C. (2014). Estimating soil moisture and the relationship with crop yield using surface temperature and vegetation index. *International Journal of Applied Earth Observation and Geoinformation*, 7, 181-192. <https://doi.org/10.1016/j.jag.2013.12.006>
- Jewan, S. Y. Y., Pagay, V., Billa, L., Tyerman, S. D., Gautam, D., Sparkes, D., Chai, H., & Singh, A. (2021). The feasibility of using a low-cost near-infrared, sensitive, consumer-grade digital camera mounted on a commercial UAV to assess Bambara groundnut yield. *International Journal of Remote Sensing*, 43(2), 393-423. <https://doi.org/10.1080/01431161.2021.1974116>
- Kaur, J., Ram, H., & Dhaliwal, S. S. (2018). Greenseeker-based nitrogen scheduling in wheat (*Triticum aestivum*) for higher nitrogen-use efficiency and productivity. *Indian Journal of Agronomy*, 63(4), 457-461. <https://doi.org/10.59797/ija.v63i4.5678>

- Li, M., Shamshiri, R. R., Weltzien, C., & Schirrmann, M. (2022). Crop monitoring using sentinel-2 and UAV multispectral imagery: a comparison case study in Northeastern Germany. *Remote Sensing*, 14, 4426. <https://doi.org/10.3390/rs14174426>
- Lukas, V., Huňady, I., Kintl, A., Mezera, J., Hammerschmidt, T., Sobotková, J., Brtnický, M., & Elbl, J. (2022). Using UAV to identify the optimal vegetation index for yield prediction of oil seed rape (*Brassica napus* L.) at the flowering stage. *Remote Sensing*, 14(19), 4953. <https://doi.org/10.3390/rs14194953>
- Mali, P., O'Hara, C. G., Shrestha, B. P., & Vijayaraj, V. (2005). Use and analysis of temporal map algebra for vegetation index compositing. *International Workshop on the Analysis of Multi-Temporal Remote Sensing Images*, 90-94. <https://doi.org/10.1109/AMTRSI.2005.1469847>
- Monostori, I., Árendás, T., Hoffman, B., Galiba, G., Gierczik, K., Szira, F., & Vágújfalvi, A. (2016). Relationship between SPAD value and grain yield can be affected by cultivar, environment, and soil nitrogen content in wheat. *Euphytica*, 211, 103-112. <https://doi.org/10.1007/s10681-016-1741-z>
- Qiao, L., Tang, W., Gao, D., Zhao, R., An, L., Li, M., Sun, H., & Song, D. (2022). UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages. *Computers and Electronics in Agriculture*, 196, 106775. <https://doi.org/10.1016/j.compag.2022.106775>
- Rahman, M. Z., Akter, S., Hoque, M., Sadeque, A., Rahman, M. M., & Islam, M. R. (2020). Impact of SPAD 502 meter based N fertilization on growth and yield attributes of wheat. *Journal of Bioscience and Agriculture Research*, 24(1), 1969-1976. <https://doi.org/10.18801/jbar.240120.241>
- Remondino, F., Spera, M. G., Nocerino, E., Menna, F., & Nex, F. (2014). State of the art in high density image matching. *The Photogrammetric Record*, 29(146), 144-166. <https://doi.org/10.1111/phor.12063>
- Retes-López, R., Moreno-Medina, S., Martín-Rivera, M. H., Ibarra-Flores, F. A., & Caughey-Espinoza, D. M. (2022). Determinación de la rentabilidad de trigo en Sonora ciclo 2021-2022. *Revista Mexicana de Agronegocios*, 50, 209-216. <https://www.redalyc.org/journal/141/14173239009/>
- Saravia, D., Valqui-Valqui, L., Salazar, W., Quille-Mamani, J., Barboza, E., Porras-Jorge, R., Injante, P., & Arbizu, C. I. (2023). Yield prediction of four bean (*Phaseolus vulgaris*) cultivars using vegetation indices based on multispectral images from UAV in an arid zone of Peru. *Drones*, 7(5), 325. <https://doi.org/10.3390/drones7050325>
- Shibayama, M., Sakamoto, T., Takada, E., Inoue, A., Morita, K., Yamaguchi, T., Takahashi, W., & Kimura, A. (2012). Estimating rice leaf greenness (SPAD) using fixed-point continuous observations of visible red and near infrared narrow-band digital images. *Plant Production Science*, 15(4), 293-309. <https://doi.org/10.1626/pps.15.293>
- Sulik, J. J., & Long, D. S. (2016). Spectral considerations for modeling yield of canola. *Remote Sensing of Environment*, 184, 161-174. <https://doi.org/10.1016/j.rse.2016.06.016>
- Taddeo, S., Dronova, I., & Depsky, N. (2019). Spectral vegetation indices of wetland greenness: Responses to vegetation structure, composition, and spatial distribution. *Remote Sensing of Environment*, 234, 111467. <https://doi.org/10.1016/j.rse.2019.111467>
- Torres-Sánchez, J., López-Granados, F., & Peña, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43-52, <https://doi.org/10.1016/j.compag.2015.03.019>
- Tsourous, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information*, 10(11), 349. <https://doi.org/10.3390/info10110349>
- U.S. Department of Agriculture - Foreign Agricultural Service (USDA-FAS). (2023). *Mexico. Grain and feed annual. Report Number: MX2023-0011*. USDA-FAS
- Villaseñor-Mir, H. E., Espitia-Rangel, E., Huerta-Espino, J., Solís-Moya, E., Ireta-Moreno, J., Osorio-Alcalá, L., & Pérez-Herrera, P. (2014). Nana F2007, cultivar de trigo para siembras de temporal en México. *Revista Mexicana de Ciencias Agrícolas*, 7, 1363-1368. <https://doi.org/10.29312/remexca.v0i7.1124>
- Wahab, I., Hall, O., & Jirström, M. (2018). Remote sensing of yields: application of UAV imagery-derived NDVI for estimating maize vigor and yields in complex farming systems in Sub-Saharan Africa. *Drones*, 2(3), 28. <https://doi.org/10.3390/drones2030028>
- Walsh, O. S., Marshall, J., Jackson, C., Nambi, E., Shafian, S., Jayawardena, D. M., Lamichhane, R., Owusu Ansah, E., & McClintick-Chess, J. R. (2022). Wheat yield and protein estimation with handheld- and UAV-based reflectance measurements. *Agrosystems, Geosciences and Environment*, 5(4), 1-14. <https://doi.org/10.1002/agg2.20309>
- Wang, F. M., Huang, J. F., Tang, Y. L., & Wang, X. Z. (2007). New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), 195-203. [https://doi.org/10.1016/S1672-6308\(07\)60027-4](https://doi.org/10.1016/S1672-6308(07)60027-4)
- Yang, B., Zhu, W., Rezaei, E. E., Li, J., Sun, Z., & Zhang, J. (2022). The optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing. *Remote Sensing*, 14(7), 1559. <https://doi.org/10.3390/rs14071559>
- Yegül, U., Emiro lu, M. B., Türker, U., Çolak, A., & Koparan, C. (2020). Modeling of in-season winter wheat nitrogen requirements using plant reflection indices. *Environmental Engineering and Management Journal*, 19(11), 1975-1982. <https://doi.org/10.30638/eemj.2020.187>
- Ye, Z., Yang, K., Lin, Y., Guo, S., Sun, Y., Chen, X., Lai, R., & Zhang, H. (2023). A comparison between pixel-based deep learning and object-based image analysis (OBIA) for individual detection of cabbage plants based on

- UAV Visible-light images. *Computers and Electronics in Agriculture*, 209, 107822. <https://doi.org/10.1016/j.compag.2023.107822>
- Yue, J., Feng, H., Li, H., Zhou, C., & Xu, K. (2021) Mapping winter-wheat biomass and grain yield based on a crop model and UAV remote sensing. *International Journal of Remote Sensing*, 42(5), 1577-1601. <https://doi.org/10.1080/01431161.2020.1823033>
- Yue, X., Hu, Y., Zhang, H., & Schmidhalter, U. (2020). Evaluation of both SPAD reading and SPAD index on estimating the plant nitrogen status of winter wheat. *International Journal of Plant Production*. 14, 67-75. <https://doi.org/10.1007/s42106-019-00068-2>
- Zeng, L., Peng, G., Meng, R., Man, J., Li, W., Xu, B., Lv, Z., & Sun, R. (2021). Wheat yield prediction based on unmanned aerial vehicles-collected red-green-blue imagery. *Remote Sensing*, 13(15), 1-19. <https://doi.org/10.3390/rs13152937>
- Zhang, J., Liu, X., Liang, Y., Cao, Q., Tian, Y., Zhu, Y., Cao, W., & Liu, X. (2019). Using a portable active sensor to monitor growth parameters and predict grain yield of winter wheat. *Sensors*, 19, 1108. <https://doi.org/10.3390/s19051108>