

Estimación de la fracción de cobertura vegetal y contenido de nitrógeno del dosel en maíz mediante sensores remotos

Fractional vegetation cover and canopy nitrogen estimation in corn through remote sensing

José Manuel Salvador-Castillo¹ , Martín Alejandro Bolaños-González^{1‡} ,
Enrique Palacios-Vélez¹, Luis Alberto Palacios-Sánchez² ,
Adolfo López-Pérez¹  y José Miguel Muñoz-Pérez¹ 

¹ Colegio de Postgraduados Campus Montecillo. Carretera México-Texcoco km 36.5, Montecillo. 56230 Texcoco, Estado de México, México.

[‡] Autor para correspondencia (martinb72@gmail.com)

² Servicios de Estudios en Ingeniería y Sistemas, S.A. de C.V. Tezozomoc 55, Colonia Cuauhtémoc. 83294 Hermosillo, Sonora, México.

RESUMEN

La eficiencia del uso de nitrógeno en la agricultura es muy baja, provocando problemas ambientales y baja productividad de los cultivos, por lo que conocer la distribución espacial y temporal de variables biofísicas que estimen su crecimiento, como la fracción de cobertura vegetal (FCV), y el contenido de nitrógeno del dosel (CND) aportará información valiosa para mejorar esta condición. El uso de imágenes satelitales de libre acceso, como las imágenes del satélite Sentinel-2 (S-2), puede facilitar esta tarea. Con base en lo anterior, se realizó un estudio en seis parcelas de maíz, cultivadas por productores de la zona de Texcoco de Mora, Estado de México, cuyo primer objetivo fue investigar la relación entre índices espectrales, estimados a partir de la reflectancia, medida con un radiómetro multiespectral a nivel de superficie y de imágenes S-2; con la FCV, estimada mediante fotografías digitales a través de la aplicación para celulares Canopeo. El segundo objetivo fue obtener un modelo lineal para estimar el CND a partir del análisis de diferentes índices espectrales. Se generaron dos modelos para estimar la FCV, a partir de la información radiométrica a nivel de superficie, la validación de estos arrojó un valor alto de $R^2 = 0.92$ y un $CME = 7.3\%$ entre datos de FCV medidos y estimados; sin embargo, en el caso de los datos estimados con imágenes S-2 se obtuvieron valores más bajos de $R^2 =$

0.67 y $CME = 17.6\%$, lo cual se atribuyó a un posible efecto de la atmósfera, ya que el periodo de estudio coincidió con la temporada de lluvias. Finalmente, en el caso del CND, los mejores resultados se obtuvieron con el modelo generado a partir del CI_{Green}^7 , con el cual se obtuvo un R^2 de 0.91 y un CME de 0.63 g m^{-2} , al comparar el CND medido con relación al estimado.

Palabras clave: Canopeo, contenido de nitrógeno del dosel (CND), fracción de cobertura vegetal (FCV), índices espectrales (IE), radiómetro.

SUMMARY

Nitrogen use efficiency of nitrogen use in agriculture is very low, causing environmental problems and low crop productivity, therefore, knowing the spatial and temporal distribution of biophysical variables such as the fractional vegetation cover (FVC) and the canopy nitrogen content (CNC) of the crops will provide valuable information to improve this condition. The use of freely accessible satellite imagery, such as Sentinel-2 (S-2) images, can facilitate this task. Due to the above, a study was carried out in six corn plots grown by producers in Texcoco de Mora, Estado de Mexico. The first objective was to investigate the relationship between spectral indices, estimated from the reflectance measured with a multispectral

Cita recomendada:

Salvador-Castillo, J. M., Bolaños-González, M. A., Palacios-Vélez, E., Palacios-Sánchez, L. A., López-Pérez, A. y Muñoz-Pérez, J. M. (2021). Estimación de la fracción de cobertura vegetal y contenido de nitrógeno del dosel en maíz mediante sensores remotos. *Terra Latinoamericana* 39: 1-11. e841. <https://doi.org/10.28940/terra.v39i0.899>

Recibido: 30 de noviembre de 2020. Aceptado: 25 de febrero de 2021.
Artículo. Volumen 39, marzo de 2021.

radiometer at surface level and S-2 images, with FVC, estimated by digital photographs through the Canopeo mobile application. The second objective was to obtain a linear model that estimated the CNC from the analysis of different spectral indices. Two models were generated to estimate FVC, from the radiometric information at surface level, their validation yielded a high value of $R^2 = 0.92$ and a $RMSE = 7.3\%$ between measured and estimated FVC data; however, in the case of the data estimated with S-2 images, lower values of $R^2 = 0.67$ and $RMSE = 17.6\%$ were obtained, which was attributed to a possible effect of the atmosphere, since the study period coincided with the rainy season. Finally, to estimate the CNC, the best results were obtained with the model generated from CI_{Green} , in which an R^2 of 0.91 and a $RMSE$ of 0.63 $g\ m^{-2}$ were obtained, when comparing the CNC measured in relation to the estimate.

Index words: *Canopeo, canopy nitrogen content (CNC), fractional vegetation cover (FVC), spectral indices (IE), radiometer.*

INTRODUCCIÓN

Fowler *et al.* (2013) reportaron que la industria de los fertilizantes, fija anualmente 120 millones de toneladas de nitrógeno reactivo. Según Raun y Johnson (1999) más del 50% de los fertilizantes nitrogenados producidos en 1995 se destinó a la producción de cereales, estos cultivos tuvieron una eficiencia de uso de nitrógeno (EUN) del 33%. En ese sentido, Omara *et al.* (2019) señalan que en 2015 la EUN, por este grupo de cultivos, subió a 35% en el mundo, siendo EUA el país con la mayor EUN (41%) mientras que India fue el país con la menor EUN (21%). La baja EUN junto con la aplicación excesiva de fertilizantes nitrogenados son una constante amenaza para los ecosistemas y la salud de las personas, debido a las diferentes rutas y transformaciones que sigue el nitrógeno en su ciclo. De acuerdo con Berger *et al.* (2020), para disminuir los efectos negativos, como la eutrofización de cuerpos de agua o emisión de gases de efecto invernadero, estos fertilizantes se deben aplicar contemplando el rendimiento económico y ambiental óptimo. Para ello, es esencial monitorear el cultivo de forma extensiva y continua a través de variables biofísicas como la fracción de cobertura vegetal (FCV), y el contenido de nitrógeno del dosel (CND). Una de las formas de

monitorear el nitrógeno en los cultivos es mediante análisis químicos, sin embargo, es una metodología destructiva, tardada y los resultados deben extrapolarse a toda la parcela. Como alternativa al análisis químico se han desarrollado metodologías para estimar el contenido de nitrógeno mediante diferentes índices espectrales (IE). Pero, no existen índices sensibles al nitrógeno, así que, para su estimación se utilizan índices sensibles a la clorofila, que se basan en la relación entre el contenido de clorofila y el contenido de nitrógeno. Una de las herramientas que aprovechan dicha relación para estimar el nitrógeno en los cultivos es el medidor portátil de clorofila o SPAD (Baret y Fourty, 1997).

Los IE, según Reyniers *et al.* (2006), son combinaciones aritméticas simples que se enfocan en el contraste entre las firmas espectrales de la vegetación que se presenta en la parte del visible e infrarrojo del espectro electromagnético. En particular; los IE sensibles a la clorofila utilizan la zona del borde rojo (*red edge*), ubicada entre los 680 y 750 nm, los cuales se han empleado para estimar el CND debido a que dicha zona se relaciona de forma directa con el contenido de clorofila; además, no presenta efectos por las variaciones en la cobertura (Horler *et al.*, 1983). El éxito de las metodologías basadas en el uso de IE para estimar el CND, se debe a que la absorción de energía electromagnética ocasionada por la clorofila, proporciona el vínculo necesario entre las observaciones realizadas por los sensores remotos y las variables relacionadas con el dosel que se utilizan para su estimación (Schlemmer *et al.*, 2013; Knyazikhin *et al.*, 2012).

De acuerdo con Song *et al.* (2017) la FCV es la relación entre el área de vegetación proyectada verticalmente y la extensión de la superficie total, generalmente expresada en relación con una unidad de área. Esta se ha utilizado, en conjunto con el índice de vegetación de diferencias normalizadas (NDVI, por sus siglas en inglés), para monitorear el crecimiento del algodón y la aplicación de riegos (Sharma y Ritchie, 2015), también para estimar el rendimiento de cultivos como la soya (de la Casa *et al.*, 2018) y el maíz (García-Martínez *et al.*, 2020). Además, es una variable clave en modelos suelo-atmósfera como Aquacrop, en el que, la FCV se utiliza para estimar el uso de agua del cultivo (Raes *et al.*, 2009). La FCV se puede obtener de forma manual a partir de la proyección de la sombra del dosel sobre una cuadrícula graduada, aunque su aplicación se restringe a superficies pequeñas. Como alternativa,

se han desarrollado métodos que estiman la FCV a partir de fotografías digitales, como es el caso de la aplicación Canopeo, la cual utiliza las proporciones de color rojo a verde (R/G), azul a verde (B/G) y el índice de exceso de verdor (2G-R-B) para clasificar un pixel como vegetación o suelo (Patrignani y Oschner, 2015).

Por la creciente necesidad de contar con información continua y espacialmente distribuida durante el ciclo de producción de cultivos como el maíz. Es conveniente utilizar la vasta información espacial proporcionada por las imágenes del satélite Sentinel-2 (S-2); las cuales destacan por su resolución espacial (10 m) y temporal, con el potencial de proporcionar una imagen semanalmente debido a su constelación de dos satélites idénticos (Clevers y Gitelson, 2013). Además, miden la reflectancia de la superficie terrestre en bandas localizadas en el borde rojo, con una resolución espacial de 20 m, lo cual les confiere un gran potencial para estimar el CND. Así, este trabajo tuvo dos objetivos; el primero fue generar un modelo para estimar la FCV a partir del NDVI, calculado con información radiométrica tomada a nivel de superficie y utilizando imágenes S-2. El segundo consistió en establecer la relación entre diferentes IE y el CND, para generar un modelo que permita estimar el CND.

MATERIALES Y MÉTODOS

La información se obtuvo en el periodo comprendido del 27 de mayo al 14 de octubre del 2019, en seis parcelas cultivadas con maíz, ubicadas en el municipio de Texcoco de Mora, en la zona oriente del Estado de México. La zona de estudio se encuentra

a 2250 m de altitud, con clima BS1 y lluvias en verano. El manejo de dichas parcelas se realizó de acuerdo con el conocimiento y experiencia de los agricultores, siendo éstas de temporal, con excepción de la parcela 2, en la cual se aplicó un riego al momento de la siembra y otro después de la emergencia. En el Cuadro 1 se presenta la ubicación, densidad de plantación y cantidad de muestreos realizados. Cuando se empezaron los muestreos las parcelas 1 y 2 iniciaban la emergencia; en la parcela 3 las plantas habían emergido 25 días antes; la parcela 4 iniciaba la etapa V6, y, por último, en las parcelas 5 y 6 las plantas tenían 17 días de haber emergido.

Durante el periodo de estudio se levantó información radiométrica y fotografías digitales de forma simultánea. Para ello, se utilizó una cámara digital (SONY) de 10 Mpx y un radiómetro multispectral (MSR, CropScan, Inc.), los cuales se colocaron en una estructura montada sobre un bastón extensible, equipado con un nivel de burbuja para asegurar la toma de datos de forma perpendicular al dosel (a nadir), a una altura de 3 m. El radiómetro tomó información en 5 bandas del espectro electromagnético; en el azul (450-520 nm), verde (520-600 nm), rojo (630-690 nm), infrarrojo cercano (760-900 nm) e infrarrojo medio (1550-1750 nm), y contó con filtros dobles en cada banda espectral que midieron de manera simultánea la radiación incidente y reflejada. Además, el programa de adquisición y calibración de datos, incluido con el sistema, facilitó la conversión analógica y digital de los voltajes, y registró el porcentaje de reflectancia en cada longitud de onda.

Cuadro 1. Ubicación, densidad de plantación e inicio y final de visitas de campo a las parcelas evaluadas en Texcoco, Estado de México. Table 1. Location, planting density and beginning and end of field visits to the plots evaluated in Texcoco, Estado de Mexico.

Parcela	Ubicación		Densidad	Visitas de campo		
	Norte	Oeste	Plantas m ⁻²	Inicio	Final	Número
1 [†]	19° 29' 37.58"	98° 55' 14.75"	4.6	31/05/2019	13/10/2019	13
2 [‡]	19° 29' 07.02"	98° 54' 57.32"	6.0	31/05/2019	20/09/2019	13
3 [†]	19° 28' 25.83"	98° 54' 31.28"	6.5	15/06/2019	13/10/2019	13
4 [‡]	19° 28' 31.36"	98° 54' 31.83"	8.0	28/06/2019	11/09/2019	11
5 [‡]	19° 28' 26.79"	98° 55' 01.24"	4.9	27/05/2019	20/08/2019	11
6 [‡]	19° 28' 35.29"	98° 54' 49.88"	6.1	27/05/2019	20/08/2019	11

[†] grano; [‡] forraje.

[†] grain; [‡] forage.

La información de campo se levantó entre las 10:30 y 14:00 horas (hora local), para evitar variaciones amplias en el ángulo cenital solar. Se seleccionaron 17 puntos de muestreo, distribuidos en forma de zigzag a lo largo de las parcelas, los cuales se cambiaron en cada visita de campo. En el punto de muestreo se tomó una fotografía y tres lecturas de reflectancia con el radiómetro, el promedio de las cuales arrojó el dato medido. Además, se realizó un muestreo foliar para determinar la concentración de nitrógeno. En el momento del muestreo, la parcela 2 se encontraba en etapa V12; las parcelas 1, 3 y 4 iniciaban la etapa de floración, y las parcelas 5 y 6 estaban en floración. Para realizar el muestreo, debido a que las parcelas mostraban un crecimiento heterogéneo, se dividió cada parcela en 4 subparcelas. Posteriormente se seleccionaron 40 plantas, de las cuales se tomó la hoja, en mejores condiciones, ubicada entre la posición 8 a 10. Las hojas se colocaron en bolsas de papel perforadas y se secaron en una estufa a 70 °C durante 72 horas. La concentración de N (%) se determinó por el método Micro-Kjeldhal en el Laboratorio de Fertilidad de Suelos y Química Ambiental del Colegio de Postgraduados.

Durante el periodo en que se desarrolló el presente trabajo, se obtuvieron 9 imágenes satelitales Sentinel-2 (S-2), de la plataforma <https://earthexplorer.usgs.gov/> propiedad del Servicio Geológico de los Estados Unidos (USGS, por sus siglas en inglés) en fechas próximas a los muestreos de campo. Las cuales, a pesar de presentar un intervalo de nubosidad del 0 al 80%, fueron útiles para el estudio debido a que presentaban nula nubosidad sobre la zona de estudio. Posteriormente, se corrigió el efecto de la atmósfera con el software Qgis versión 3.8.2, por medio del complemento Semi-Automatic Classification Plugin (SCP) que utiliza la técnica de sustracción de objeto oscuro (Chavez, 1996). Por último, se extrajeron los polígonos de las parcelas para su análisis.

A partir de las fotografías digitales se estimó la FCV, empleando la aplicación Canopeo, desarrollada por Patrignani y Ochsner (2015). Por otro lado, la información radiométrica tomada a nivel de superficie se utilizó para estimar el NDVI con la fórmula presentada en el Cuadro 2, al cual se le identificará en adelante como $NDVI_R$. De estas dos variables se obtuvo el valor promedio de las diferentes parcelas por cada visita de campo. De igual manera, a partir de las imágenes S-2 se estimó el NDVI, el cual se identificará

como $NDVI_S$. Dicha información permitió generar un modelo para estimar la FCV a través del $NDVI_R$ y del $NDVI_S$. Sin embargo, en el caso del $NDVI_S$ fue necesario realizar una interpolación lineal simple para disponer de información que se pudiera comparar con la FCV estimada en campo.

Para calcular el CND, se multiplicó la concentración de nitrógeno por el índice de área foliar (IAF), y por el peso específico de la hoja. Para estimar el IAF, se utilizó la relación $((11.266 \times NDVI_S) - 4.007)$ propuesta por Kross *et al.* (2015). Entre el CND y el valor promedio de los IE, estimados para cada cuadrante de muestreo, presentados en el Cuadro 2, se obtuvieron relaciones lineales para estimar el CND. Debido a las condiciones de nubosidad presentes en la imagen del día 5 de agosto la estimación del IAF y de los diferentes IE se realizó con los datos de la imagen tomada el 10 de agosto. De manera que el análisis del CND se realizó con la imagen tomada 5 días después de que se realizó el muestro de campo.

Análisis Estadístico

Se utilizaron dos parámetros de eficiencia estadística. El coeficiente de determinación (R^2), el cual indica la capacidad de un modelo para replicar sus resultados (Ecuación 1 y 2), y el cuadrado medio del error (CME), el cual mide la variación de los valores calculados respecto a los observados (Ecuación 3).

$$R^2 = \left(\frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{[\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2]^{\frac{1}{2}}} \right)^2 \quad (1)$$

$$R^2 = \frac{(\sum y_i^2 - \left[\frac{(\sum y_i)^2}{n} \right]) - \sum(y_i - \hat{y}_i)}{(\sum y_i^2 - \left[\frac{(\sum y_i)^2}{n} \right])} \quad (2)$$

$$CME = \left(\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \right)^{\frac{1}{2}} \quad (3)$$

donde: x_i = i-esima observación de la variable x ; \bar{x} = valor promedio de la variable x ; y_i = i-esima observación de la variable y ; \bar{y} = valor promedio de la variable y ; \hat{y} = valor estimado de la variable y ; n = número de observaciones.

Cuadro 2. Índices espectrales analizados.
Table 2. Spectral indices analyzed.

Índice	Fórmula	Bandas	Fuente
Cl _{Red-edge} [†]	$\left(\frac{R_{750-800}}{R_{695-740}}\right) - 1$	B5 y B7	Gitelson <i>et al.</i> (2003)
Cl _{Green} [‡]	$\left(\frac{R_{750-800}}{R_{520-585}}\right) - 1$	B3 y B7	Gitelson <i>et al.</i> (2003)
NDVI [§]	$\frac{NIR_{783} - R_{665}}{NIR_{783} + R_{665}}$	B4 y B8	Rouse <i>et al.</i> (1974)
IRECI [¶]	$\frac{NIR_{783} - R_{665}}{\left(\frac{R_{705}}{R_{740}}\right)}$	B4, B5, B6 y B7	Frampton <i>et al.</i> (2013)
ReChi [#]	$\frac{R_{750} - R_{700}}{R_{700}}$	B6 y B5	Gitelson y Merzlyak (1996)
TCARI/OSAVI [705,750] ^{††}	$\frac{3 \left[(R_{750} - R_{705}) - 0.2(R_{750} - R_{550}) \left(\frac{R_{750}}{R_{705}}\right) \right]}{(1 + 0.16)(R_{750} - R_{705}) / (R_{750} + R_{705} + 0.16)}$	B3, B5 y B6	Wu <i>et al.</i> (2008)
MCARI/OSAVI [705,750] ^{††}	$\frac{(R_{750} - R_{705}) - 0.2(R_{750} - R_{550}) \left(\frac{R_{750}}{R_{705}}\right)}{(1 + 0.16)(R_{750} - R_{705}) / (R_{750} + R_{705} + 0.16)}$	B3, B5 y B6	Wu <i>et al.</i> (2008)
MTCI ^{§§}	$\frac{R_{753.75} - R_{708.75}}{R_{708.75} - R_{681.25}}$	B7, B5 y B4	Dash y Curran (2004)

[†] Modelo de borde rojo; [‡] Modelo verde; [§] Índice de vegetación de diferencias normalizadas; [¶] Índice de clorofila de borde rojo invertido; [#] Índice de clorofila de borde rojo; ^{††} Índice de relación de absorción de clorofila transformada/índice de vegetación optimizado ajustado al suelo; ^{§§} Índice de relación de absorción de clorofila modificado/índice de vegetación optimizado ajustado al suelo; ^{§§} Índice de clorofila terrestre MERIS.

[†] Red border model; [‡] Green model; [§] Vegetation index of normalized differences; [¶] Inverted red border chlorophyll index; [#] Red edge chlorophyll index; ^{††} Ratio of transformed chlorophyll uptake ratio/optimized vegetation index adjusted to the soil; ^{§§} Modified chlorophyll absorption ratio/optimized vegetation index adjusted to the soil; ^{§§} MERIS terrestrial chlorophyll index.

RESULTADOS Y DISCUSIÓN

Estimación de la FCV Utilizando Información Radiométrica

Calera *et al.* (2001) y Er-Raki *et al.* (2013) señalan que la fracción de cobertura vegetal (FCV) y el índice de vegetación de diferencias normalizadas (NDVI) presentan una fuerte relación lineal, de manera que es posible generar un modelo que estime la FCV a partir

del NDVI. Con información de las parcelas 2, 3 y 4, las cuales se seleccionaron al azar, se obtuvo la relación entre el NDVI_R y la FCV (Figura 1), mientras que con las 3 parcelas restantes se validaron los modelos. El primer modelo (FCV = 84.544 (NDVI_R-0.14)) de dicha relación, al cual se restó el valor mínimo de NDVI_R, funcionó de forma adecuada hasta valores de NDVI_R iguales a 0.6, valor que se presentó a una FCV de 40%, entre la etapa V8 a V10. Purevdorj *et al.* (1998) encontraron, al analizar el NDVI para estimar

la FCV en pasto, que las superposiciones de hojas causan grandes errores al estimar la FCV. Es decir, al incrementar el IAF sobre una misma cantidad de cobertura, la reflectancia espectral cambia modificando el NDVI y por lo tanto la FCV estimada. Estos autores encontraron que a partir del 40% de FCV el error en la estimación de esta variable se incrementa, tal como se observó en este estudio.

Para estimar la FCV a valores de $NDVI_R$ mayores de 0.6 se utilizó el segundo modelo ($FCV = (112.18 \times NDVI_R) - 21.467$). Sin embargo, el NDVI experimenta el fenómeno de saturación ya que la banda roja alcanza un punto de saturación más rápido, debido a la presencia de pigmentos fotosintéticos, que la banda del infrarrojo (Paz *et al.*, 2014). En ese sentido, Gitelson *et al.* (2003) y Schlemmer *et al.* (2013) mencionan que, en la banda roja el coeficiente de absorción de la clorofila es alto, por lo que al alcanzarse un contenido de clorofila cercano a 0.8 g m^{-2} o un CND de 4 g m^{-2} , lo cual ocurre a valores tan bajos de IAF como 2.0, la reflectancia en la banda roja del espectro electromagnético se satura. De manera que, el NDVI crece de forma lineal en las etapas tempranas de crecimiento y se vuelve asintótico cuando el IAF se incrementa (de la Casa *et al.*, 2014; Jiang *et al.*, 2006).

Respecto a la aplicación Canopeo, se observó que, en etapas avanzadas de crecimiento, subestima la FCV, efecto que se debe al sombreado que ejercen las hojas superiores del dosel. Según Calera *et al.* (2001)




Figura 1. Relación entre la fracción de cobertura vegetal (FCV) y el índice de vegetación de diferencias normalizadas ($NDVI_R$) con información de las parcelas 2, 3 y 4.

Figure 1. Estimated fractional vegetation cover (FCV) and normalized differences of vegetation index ($NDVI_R$) relationship with information from plots 2, 3 and 4.

esta situación dificulta la estimación de la FCV con fotografías digitales. Además, durante la floración, las espigas no son detectadas como vegetación verde, subestimando aún más la FCV, ya que éstas se encuentran más cercanas de la cámara y ocupan una mayor porción de la fotografía.

Los modelos se validaron con datos de las parcelas 1, 5 y 6. Así, graficando los valores de la FCV estimados contra los medidos en dichas parcelas se obtuvo una relación muy estrecha, con un $R^2 = 0.92$, un $CME = 7.3\%$ y una pendiente muy cercana a 1 (Figura 2). Al realizar la misma comparación, Er-Raki *et al.* (2013) obtuvieron un R^2 de 0.79 y un CME de 9% en vid, mientras que, en trigo, Er-Raki *et al.* (2007) obtuvieron un R^2 de 0.89 y un CME de 10%.

Las mejores estimaciones de este trabajo con respecto al realizado en vid, se deben a que la vid se distribuye en hileras con poca cobertura vegetal, que al dejar porciones de suelo desnudo influyen en el NDVI estimado (Campos *et al.*, 2014). Respecto al trigo, el menor rendimiento de los datos estimados se puede atribuir a que dichos autores utilizaron solo un modelo para estimar la FCV durante todo el ciclo de cultivo. Por otro lado, en soya, de la Casa *et al.* (2018) obtuvieron un R^2 de 0.99 al comparar la FCV medida contra la FCV estimada mediante el uso de tres modelos para diferentes rangos de $NDVI_R$. Por lo cual, el uso de relaciones diferentes en distintas etapas del cultivo proporciona una mejor estimación de la FCV.

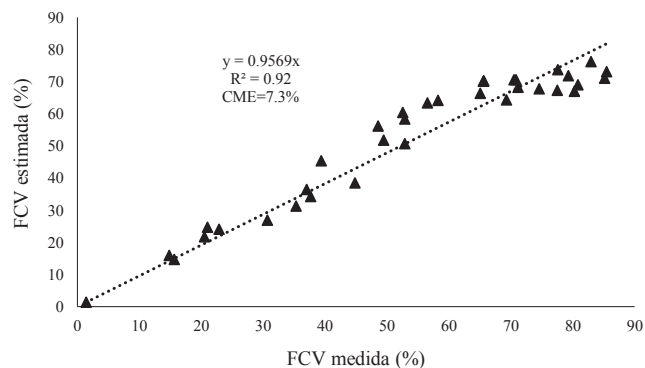


Figura 2. Relación entre la fracción de cobertura vegetal (FCV) estimada empleando los modelos generados y la FCV medida con la aplicación Canopeo.

Figure 2. Estimated fractional vegetation cover (FCV) relationship using the generated models and the FCV measured with the Canopeo application.

Estimación de la FCV Utilizando Imágenes Sentinel-2

Con la finalidad de conocer la distribución espacial de la FCV en la parcela, se obtuvo una relación lineal entre el $NDVI_s$ y la FCV. La generación del modelo se realizó con información de las parcelas 2, 3 y 4, estas coinciden con las parcelas usadas para estimar la FCV con el NDVI calculado con datos del radiómetro. En este caso, también se generaron dos relaciones (Figura 3); la primera $FCV=101.21(NDVI_s-0.14)$ arrojó estimaciones adecuadas hasta valores de $NDVI_s$ igual a 0.5, para valores mayores se utilizó la relación $FCV=(145.26NDVI_s)-28.257$.

El R^2 obtenido en este trabajo fue superior al obtenido en trigo por Jin *et al.* (2017), quienes al relacionar la FCV con el Índice de Vegetación Triangular Modificado 2 (MTVI2), estimado a partir de las imágenes HJ-1A/B con resolución espacial de 30 m, reportaron un R^2 de 0.58 y un CME de 15.75%. En cambio, Johnson y Trout (2012), al relacionar la FCV de diferentes cultivos hortícolas con el NDVI estimado mediante imágenes Landsat 5, encontraron un $R^2 = 0.96$ y un CME = 6.2%. En ese sentido, Cuesta *et al.* (2005) obtuvieron un R^2 de 0.94 al relacionar la FCV, de varios cultivos, con el NDVI estimado a partir de imágenes Landsat 5 y Landsat 7.

Los modelos generados a partir del $NDVI_s$ se validaron con información de las parcelas 1, 5 y 6. El $R^2 = 0.67$ obtenido al contrastar la FCV medida con




Figura 3. Relación entre la fracción de cobertura vegetal (FCV) y el índice de vegetación de diferencias normalizadas (NDVI) estimado con las imágenes Sentinel-2 ($NDVI_s$).

Figure 3. Estimated fractional vegetation cover (FCV) and normalized differences of vegetation index (NDVI) estimated with Sentinel-2 images ($NDVI_s$).

la FCV estimada (Figura 4) es bajo en comparación al reportado en soya por de la Casa *et al.* (2018), quienes obtuvieron un R^2 de 0.96 y 0.94 usando imágenes Landsat 7 y 8 e imágenes PROVA-V, respectivamente, a pesar de que estas últimas tienen una resolución espacial de 100 m.

La diferencia tan marcada con respecto a este trabajo, se puede atribuir al tamaño de las parcelas evaluadas; en este caso se trabajó con parcelas de aproximadamente una hectárea, mientras que de la Casa *et al.* (2018) desarrollaron su trabajo en una parcela de soya con una extensión de 47 ha. Además, en este estudio se presentó una gran heterogeneidad en el crecimiento del cultivo, provocada principalmente por la diferente densidad de siembra en las parcelas evaluadas. Otros factores que pudieron influir en la heterogeneidad observada fueron; en la parcela 5 el estrés hídrico y la presencia de salinidad, ya que este fue un suelo de reciente incorporación a la agricultura (3 años), y en las parcelas 1, 3 y 6 se presentó un estrés hídrico constante. Por otro lado, el valor de $R^2 = 0.67$ encontrado en este trabajo es superior al obtenido por Jin *et al.* (2017), dichos autores reportaron un R^2 de 0.58 y un CME de 15.89%.

Estimación del Contenido de Nitrógeno del Dosel

Para determinar la relación entre el CND y los IE presentados en el Cuadro 2, se utilizó la información de las subparcelas de muestreo




Figura 4. Relación entre la fracción de cobertura vegetal (FCV) medida con la aplicación Canopeo y la FCV estimada con los modelos de la Figura 3.

Figure 4. Estimated fractional vegetation cover (FCV) relationship measured with the Canopeo application and the FCV estimated with the models in Figure 3.

correspondientes a las parcelas 2, 3 y 5, generadas durante el muestreo foliar del cultivo, estas parcelas se seleccionaron al azar. El resultado de dicha relación se presenta en el Cuadro 3. De los IE analizados, el MTCI fue el que arrojó el menor coeficiente de correlación con el CND ($R^2 = 0.30$), lo cual contrasta con los resultados obtenidos por Clevers y Kooistra (2012) quienes obtuvieron un R^2 de 0.80 y 0.68 en pasto y papa, respectivamente. Para el mismo índice, en trigo, González-Piqueras *et al.* (2017) reportaron un R^2 de 0.93. Por otro lado, Schlemmer *et al.* (2013) señalan que el MTCI, en maíz, no presentó efectos de saturación para valores de CND menores de 10 g m^{-2} y reportaron un R^2 de 0.80. Una probable explicación del bajo rendimiento del MTCI en este trabajo, es que el ancho de las bandas 4 y 6 de las imágenes S-2 se encuentran fuera del rango óptimo para su estimación.

El NDVI presentó un R^2 de 0.60, menor al encontrado por Martínez (2017), quien reportó un R^2 de 0.65 al relacionar dicho índice con el CND. Su bajo rendimiento se debe al efecto de saturación que se da a partir de un CND de 4 g m^{-2} (Schlemmer *et al.*, 2013). La relación TCARI/OSAVI (705,750) arrojó un R^2 de 0.79, semejante al $R^2 = 0.75$ obtenido por Clevers y Kooistra (2012) en pasto. Por otro lado, con la relación entre el CND y el MCARI/OSAVI (705,750) se obtuvo un R^2 de 0.90, mayor al $R^2 = 0.83$ reportado por Clevers y Gitelson (2013) en papa.

Con respecto al IRECI, dicho índice mostró valores de R^2 de 0.91, mayor al $R^2 = 0.73$ encontrado

por Martínez (2017) en diferentes cultivos. Asimismo, con el $CI_{\text{Red-edge}}$ se obtuvo un R^2 de 0.93, en tanto que, en maíz, Schlemmer *et al.* (2013) reportaron un R^2 de 0.87 y González-Piqueras *et al.* (2017) un R^2 de 0.91 en trigo. Mientras que con el CI_{Green} se registró un R^2 de 0.84 y con el ReChi un R^2 de 0.89. Por otro lado, Martínez (2017) encontró, en diferentes cultivos incluido maíz, una mejor relación entre el CND y el CI_{Green} , seguido del ReChi y del $CI_{\text{Red-edge}}$, para los cuales, reportó valores de R^2 de 0.88, 0.86 y 0.85, respectivamente. Clevers y Gitelson (2013) reportaron un mejor rendimiento del CI_{Green} ($R^2 = 0.77$) que del $CI_{\text{Red-edge}}$ ($R^2 = 0.75$) en pasto, mientras que, en papa, ambos índices presentaron un R^2 de 0.89. La validación de los modelos presentados en el Cuadro 3, se realizó con la información de las subparcelas 1, 4 y 6. En el Cuadro 4 se presenta la relación entre el CND medido y el CND estimado.

El CI_{Green} presentó el mayor R^2 y el menor CME, 0.91 y 0.63 g m^{-2} , respectivamente, de un promedio de CND de 5.47 g m^{-2} , seguido del $CI_{\text{Red-edge}}$ y ReChi. La comparación entre los datos medidos y los estimados a partir del modelo generado con el CI_{Green} se presentan en la Figura 5. En cambio, Clevers y Kooistra (2012) encontraron que el $CI_{\text{Red-edge}}$ era el mejor IE para estimar el CND, al comparar datos de CND medidos contra estimados, dichos autores reportan un R^2 de 0.77 y un CME de 0.82 g m^{-2} con respecto a un promedio de CND medido de 3.44 g m^{-2} en pasto. Al respecto, Rama *et al.* (2008) señalan que

Cuadro 3. Relación entre los diferentes índices espectrales y el contenido de nitrógeno del dosel.
Table 3. Different spectral indices and nitrogen content of the canopy relationship.

Índice	Modelo	R^2	CME g m^{-2}
$CI_{\text{Red-edge}}$	$y = 2.0675x$	0.93	0.47
CI_{Green}	$y = 1.9314x$	0.84	0.70
NDVI	$y = 8.3203x$	0.60	1.11
IRECI	$y = 6.1795x$	0.91	0.51
ReChi	$y = 3.2461x$	0.89	0.57
TCARI/OSAVI(705,750)	$y = -10.96x + 12.888$	0.79	0.81
MCARI/OSAVI(705,750)	$y = -48.756x + 15.823$	0.90	0.55
MTCI	$y = 0.6211x$	0.30	1.47

Cuadro 4. Relación entre contenido de nitrógeno del dosel (CND) medido y CND estimado usando los modelos del Cuadro 3.
Table 4. Canopy nitrogen content (CND) and estimated CND relationship using the models in Table 3.

Índice	Modelo	R ²	CME g m ⁻²
CI _{Red-edge}	$y = 1.0636x$	0.87	0.84
CI _{Green}	$y = 0.9988x$	0.91	0.63
NDVI	$y = 0.3901x + 3.3818$	0.80	1.19
IRECI	$y = 1.0114x$	0.78	1.37
ReChi	$y = 1.0108x$	0.81	0.74
TCARI/OSAVI(705,750)	$y = 0.4089x + 4.1685$	0.72	1.68
MCARI/OSAVI(705,750)	$y = 1.122x$	0.13	1.35
MTCI	$y = 1.0366x$	0.60	0.84

la acumulación de N expresa mayores diferencias en las reflectancias en 560 y 550 nm. Lo cual podría explicar, de forma parcial, el mejor desempeño del CI_{Green} en la estimación del CND. Además, mencionan que el funcionamiento de los IE en la estimación del CND, se debe a que esta variable se relaciona directamente con el IAF y el peso específico de la hoja. Así, aunque la información obtenida a través de las imágenes de satélite incluye la reflectancia de las hojas, los tallos, las espigas, el suelo y demás componentes, la estimación del CND a nivel del dosel es viable.

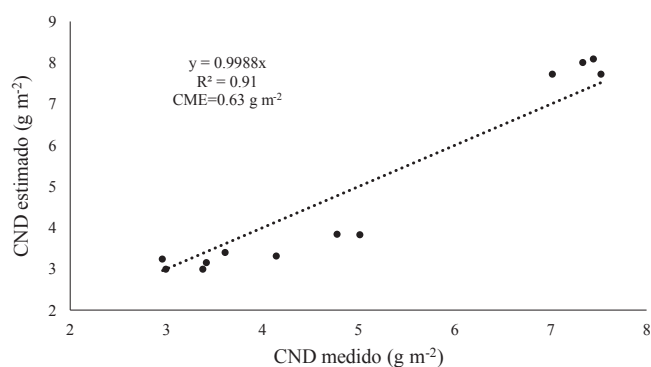


Figura 5. Relación entre el contenido de nitrógeno del dosel (CND) medido y estimado (CI_{Green}).

Figura 5. Canopy nitrogen content (CND) and estimated (CI_{Green}).

CONCLUSIONES

La fracción de cobertura vegetal (FCV) calculada con los modelos generados a partir del índice de vegetación de diferencias normalizadas (NDVI), usando información radiométrica a nivel de campo, mostró mejores estimaciones de la FCV que los modelos obtenidos mediante las imágenes Sentinel-2. Estos resultados se atribuyen a la escala de adquisición de los datos, parcelas pequeñas y heterogéneas, y al efecto atmosférico provocado por la frecuente nubosidad y humedad ambiental en la zona durante el desarrollo de este trabajo. Debido a que las fotografías captan una superficie pequeña, en futuras investigaciones se propone estimar la FCV mediante videos, utilizando la aplicación Canopeo. De esta manera, se incrementaría la superficie de muestreo y se podría obtener un modelo más adecuado para estimar la FCV de forma extensiva.

Por otro lado, el CI_{Red-edge} fue el índice que mejor se relacionó con el contenido de nitrógeno del dosel. Sin embargo, al momento de comparar el contenido de nitrógeno medido contra el estimado, el modelo obtenido con el CI_{Green} ($y = 1.9314x$) fue el que mostró las mejores aproximaciones. Así, dicho modelo se podría utilizar para estimar el contenido de nitrógeno del dosel, durante la etapa previa al inicio de la floración, en la zona de Texcoco.

DISPONIBILIDAD DE DATOS

Los conjuntos de datos utilizados o analizados durante el estudio actual están en disponibilidad del autor a solicitud razonable.

CONFLICTO DE INTERESES

Los autores declaran que no tienen intereses en competencia.

FONDOS

Este estudio se realizó con apoyo de una beca de maestría financiada por CONACYT.

CONTRIBUCIÓN DE LOS AUTORES

Preparación del borrador original y levantamiento de información: J.M.S.C. Revisión del borrador original, de la metodología y de los cálculos realizados: M.A.B.G. Revisión del borrador original: E.P.V. y A.L.P. Revisión del borrador original y de los cálculos realizados: L.A.P.S. Levantamiento de información de campo y revisión de bases de datos: J.M.M.P.

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada para estudio de maestría del ingeniero José Manuel Salvador Castillo y a los productores cooperantes.

LITERATURA CITADA

- Baret, F. and T. Fourty. 1997. Radiometric estimates of nitrogen status of leaves and canopies. pp. 201-227. *In*: G. Lemaire (ed.). *Diagnosis of nitrogen status in crops*. Springer-Verlag. Heidelberg, Germany. doi: https://doi.org/10.1007/978-3-642-60684-7_12.
- Berger, K., J. Verrelst, J. B. Féret, Z. Wang, M. Woche, M. Strathmann, M. Danner, W. Mauser, and T. Hank. 2020. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sens. Environ.* 242: 111758. doi: <https://doi.org/10.1016/j.rse.2020.111758>.
- Calera, A., C. Martínez, and J. Melia. 2001. A procedure for obtaining green plant cover: relation to NDVI in a case study for barley. *Int. J. Remote Sens.* 22: 3357-3362. doi: <https://doi.org/10.1080/01431160010020100>.
- Campos, I., C. M. Neale, M. Llanos L., C. Balbontín, and A. Calera. 2014. Analyzing the effect of shadow on the relationship between ground cover and vegetation indices by using spectral mixture and radiative transfer models. *J. Appl. Remote Sens.* 8:1-21. Article 083562. doi: <http://dx.doi.org/10.1117/1.JRS.8.083562>
- Chavez, P. S. 1996. Image-based atmospheric corrections-revisited and improved. *Photogramm. Eng. Remote Sens.* 62: 1025-1036.
- Clevers, J. G. P. W. and L. Kooistra. 2012. Using hyperspectral remote sensing data for retrieving total canopy chlorophyll and nitrogen content. *IEEE J. Sel. Topics Appl. Earth Obs. Remote Sens.* 5: 574-583. doi: <http://dx.doi.org/10.1109/JSTARS.2011.2176468>
- Clevers, J. G. P. W. and A. A. Gitelson. 2013. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *Int. J. Appl. Earth Obs. Geoinf.* 23: 344-351. doi: <https://doi.org/10.1016/j.jag.2012.10.008>.
- Cuesta, A., A. Montoro, A. M. Jochum, P. López y A. Calera. 2005. Metodología operativa para la obtención del coeficiente de cultivo desde imágenes satelitales. *ITEA* 101: 212-224.
- Dash, J. and P. J. Curran. 2004. The MERIS terrestrial chlorophyll index. *Int. J. Remote Sens.* 25: 5403-5413. doi: <https://doi.org/10.1080/0143116042000274015>.
- De la Casa, A., G. G. Ovando, A. C. Ravelo, E. G. Abril, and H. Bergamaschi. 2014. Estimating maize ground cover using spectral data from Aqua-MODIS in Córdoba, Argentina. *Int. J. Remote Sens.* 35: 1295-1308. doi: <https://doi.org/10.1080/01431161.2013.876119>.
- De la Casa, A., G. Ovando, L. Bressanini, J. Martínez, G. Díaz, and C. Miranda. 2018. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. *ISPRS J. Photogramm. Remote Sens.* 146: 531-547. doi: <https://doi.org/10.1016/j.isprsjprs.2018.10.018>.
- Er-Raki, S., A. Chehbouni, N. Guemouria, B. Duchemin, J. Ezzahar, and R. Hadria. 2007. Combining FAO-56 model and ground-based remote sensing to estimate water consumptions of wheat crops in a semi-arid region. *Agric. Water Manage.* 87: 41-54. doi: <https://doi.org/10.1016/j.agwat.2006.02.004>.
- Er-Raki, S., J. C. Rodríguez, J. Garatuza-Payan, C. J. Watts, and A. Chehbouni. 2013. Determination of crop evapotranspiration of table grapes in a semi-arid region of Northwest Mexico using multi-spectral vegetation index. *Agric. Water Manage.* 122: 12-19. doi: <https://doi.org/10.1016/j.agwat.2013.02.007>.
- Fowler, D., M. Coyle, U. Skiba, M. A. Sutton, J. N. Cape, S. Reis, L. J. Sheppard, A. Jenkins B. Grizzetti, J. N. Galloway, P. Vitousek, A. Leach, A. F. Bouwman, K. Butterbach B., F. Dentener, D. Stevenson, M. Amann, and M. Voss. 2013. The global nitrogen cycle in the twenty-first century. *Phil. Trans. R. Soc. B* 368: 1621. doi: <https://doi.org/10.1098/rstb.2013.0164>.
- Frampton, W. J., J. Dash, G. Watmough, and E. J. Milton. 2013. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS J. Photogramm. Remote Sens.* 82: 83-92. doi: <https://doi.org/10.1016/j.isprsjprs.2013.04.007>.

- García-Martínez, H., H. Flores-Magdaleno, R. Ascencio-Hernández, A. Khalil-Gardezi, L. Tijerina-Chávez, O. R. Mancilla-Villa, and M. A. Vázquez-Peña. 2020. Corn grain yield estimation from vegetation indices, canopy cover, plant density, and a neural network using multispectral and RGB images acquired with unmanned aerial vehicles. *Agriculture* 10: 277. doi: <https://doi.org/10.3390/agriculture10070277>.
- Gitelson, A. A. and M. N. Merzlyak. 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *J. Plant Physiol.* 148: 494-500. doi: [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7).
- Gitelson, A. A., Y. Gritz, and M. N. Merzlyak. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *J. Plant Physiol.* 160: 271-282. doi: <https://doi.org/10.1078/0176-1617-00887>.
- González-Piqueras, J., H. Lopez-Corcoles, S. Sánchez, J. Villodre, V. Bodas, I. Campos, A. Osann, and A. Calera. 2017. Monitoring crop N status by using red edge-based indices. *ECPA* 8: 338-342. doi: <https://doi.org/10.1017/S2040470017000243>.
- Horler, D. N. H., M. Dockray, and J. Barber. 1983. The red edge of plant reflectance. *Int. J. Remote Sens.* 4: 273-288. doi: <https://doi.org/10.1080/01431168308948546>.
- Jiang, Z., A. R. Huete, J. Chen, Y. Chen, J. Li, G. Yan, and X. Zhang. 2006. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sens. Environ.* 101: 366-378. doi: <https://doi.org/10.1016/j.rse.2006.01.003>.
- Jin, X., Z. Li, G. Yang, H. Yang, H. Feng, X. Xu, J. Wang, X. Li, and J. Luo. 2017. Winter wheat yield estimation base on multi-source medium resolution optical and radar imaging data and AquaCrop model using the particle swarm optimization algorithm. *ISPRS J. Photogramm. Remote Sens.* 126: 24-37. doi: <https://doi.org/10.1016/j.isprsjprs.2017.02.001>.
- Johnson, L. F. and T. J. Trout. 2012. Satellite NDVI assisted monitoring of vegetable crop evapotranspiration in California's San Joaquin Valley. *Remote Sens.* 4: 439-455. doi: <https://doi.org/10.3390/rs4020439>.
- Knyazikhin, Y., M. A. Schull, P. Stenberg, M. Möttus, M. Rautiainen, Y. Yang, A. Marshak, P. L. Carmona, R. K. Kaufmann, P. Lewis, M. I. Disney, V. Vanderbilt, A. B. Davis, F. Baret, S. Jacquemoud, A. Lyapustin, and R. B. Myneni. 2012. Hyperspectral remote sensing of foliar nitrogen content. *PNAS* 110: E185-E192. doi: <https://doi.org/10.1073/pnas.1210196109>.
- Kross, A., H. McNairn, D. Lapen, M. Sunohara, and C. Champagne. 2015. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *Int. J. Appl. Earth Obs. Geoinf.* 34:235-248. doi: <https://doi.org/10.1016/j.jag.2014.08.002>.
- Martínez M., L. J. 2017. Relationship between crop nutritional status, spectral measurements and Sentinel 2 images. *Agron. Colomb.* 35: 205-215. doi: <http://dx.doi.org/10.15446/agron.colomb.v35n2.62875>.
- Omara, P., L. Aula, F. Oyebiyi, and W. R. Raun. 2019. World cereal nitrogen use efficiency trends: Review and current knowledge. *Agrosyst. Geosci. Environ.* 2: 1-8. Article 180045. doi: <https://doi.org/10.2134/age2018.10.0045>.
- Patrignani, A. and T. E. Ochsner. 2015. Canopeo: A powerful new tool for measuring fractional green canopy cover. *Agron. J.* 107: 2312-2320. doi: <https://doi.org/10.2134/agronj15.0150>.
- Paz P., F., M. E. Romero S., E. Palacios V., M. Bolaños G., J. R. Valdez L. y A. Aldrete. 2014. Alcances y limitaciones de los índices espectrales de la vegetación: marco teórico. *Terra Latinoamericana* 32: 177-194.
- Purevdorj, TS., R. Tateishi, T. Ishiyama, and Y. Honda. 1998. Relationships between percent vegetation cover and vegetation indices. *Int. J. Remote Sens.* 19: 3519-3535. doi: <https://doi.org/10.1080/014311698213795>.
- Rama R., N., P. K. Garg, S. K. Ghosh, and V. K. Dadhwal. 2008. Estimation of leaf total chlorophyll and nitrogen concentrations using hyperspectral satellite imagery. *J. Agric. Sci.* 146: 65-75. doi: <https://doi.org/10.1017/S0021859607007514>.
- Raes, D., P. Steduto, T. C. Hsio, and E. Fereres. 2009. AquaCrop—the FAO crop model to simulate yield response to water: II. Main algorithms and software description. *Agron. J.* 101: 438-447. doi: <https://doi.org/10.2134/agronj2008.0140s>.
- Raun, W. R. and G. V. Johnson. 1999. Improving nitrogen use efficiency for cereal production. *Agron. J.* 91: 357-363. doi: <https://doi.org/10.2134/agronj1999.00021962009100030001x>.
- Reyniers, M., D. J. J. Walvoort, and J. de Baardemaaker. 2006. A linear model to predict with a multi-spectral radiometer the amount of nitrogen in winter wheat. *Int. J. Remote Sens.* 27: 4159-4179. doi: <https://doi.org/10.1080/01431160600791650>.
- Rouse, J. W., R. H. Hass, J. A. Schell, D. W. Deering, and J. C. Harlan. 1974. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. NASA/GSFC, Type III, Final report, RSC 1978-4, Texas A&M Univ. Remote Sensing Center. College Station, Texas, USA.
- Schlemmer, M., A. Gitelson, J. Schepers, R. Ferguson, Y. Peng, J. Shanahan, and D. Rundquist. 2013. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. *Int. J. Appl. Earth Obs. Geoinf.* 25: 47-54. doi: <https://doi.org/10.1016/j.jag.2013.04.003>.
- Song, W., X. Mu, G. Ruan, Z. Gao, L. Li, and G. Yan. 2017. Estimating fractional vegetation cover and the vegetation index of bare soil and highly dense vegetation with a physically based method. *Int. J. Appl. Earth Obs. Geoinf.* 58:168-176. doi: <https://doi.org/10.1016/j.jag.2017.01.015>.
- Sharma, B. and G. L. Ritchie. 2015. High-throughput phenotyping of cotton in multiple irrigation environments. *Crop Sci.* 55: 958-969. doi: <https://doi.org/10.2135/cropsci2014.04.0310>.
- Wu, C., Z. Niu, Q. Tang, and W. Huang. 2008. Estimating chlorophyll content from hyperspectral vegetation indices: modeling and validation. *Agric. Forest Meteorol.* 148:1230-1241. doi: <https://doi.org/10.1016/j.agrformet.2008.03.005>.