



50 AÑOS
PENSANDO
EL FUTURO

XIII
CONGRESO
NACIONAL
DE MAÍZ

FENOTIPADO DE ALTO RENDIMIENTO PARA ESTIMAR LA FRACCIÓN DE RADIACIÓN INTERCEPTADA EN MAÍZ MEDIANTE UN DRON

Menes, J. F.¹; Galizia, L.A.¹; Portillo, J.E.^{1,2}; Alvarez Prado, S.^{3,4}; Oyarzabal, M.^{5,6,7}

¹ INTA Estación Experimental Agropecuaria Pergamino. Av. Frondizi (Ruta 32) km 4,5, B2700, Pergamino, Buenos Aires, Argentina. menes.josefernando@inta.gob.ar; galizia.luciana@inta.gob.ar; portillo.javier@inta.gob.ar

² Universidad nacional del noroeste de la provincia de Buenos Aires. Av. Libertad 555, B6000 Junín, Buenos Aires, Argentina.

³ IICAR – CONICET, Consejo Nacional de Investigaciones Científicas y Técnicas, Facultad de Ciencias Agrarias, Universidad Nacional de Rosario, Campo Experimental Villarino S/N, S2125ZAA Zavalla, Prov. de Santa Fe, Argentina. psalvare@agro.uba.ar

⁴ Cátedra de Sistemas de Cultivos Extensivos-GIMUCE. Facultad de Ciencias Agrarias, Universidad Nacional de Rosario, Campo Experimental Villarino S/N, S2125ZAA Zavalla, Prov. de Santa Fe, Argentina

⁵ Conicet y AER Coronel Suárez, EEA Cesáreo Naredo, INTA, Argentina. oyarzaba@agro.uba.ar

⁶ Cátedra de Agrometeorología, Departamento de Agronomía, Universidad Nacional del Sur, Argentina.

⁷ Departamento de Métodos Cuantitativos y Sistemas de Información, Facultad de Agronomía, Universidad de Buenos Aires, Argentina.

HIGH-THROUGHPUT PHENOTYPING TO ESTIMATE THE FRACTION OF INTERCEPTED RADIATION IN MAIZE USING A DRONE.

The fraction of intercepted photosynthetically active radiation (fIPAR) is a key phenotypic variable for maize growth and yield. Its assessment in breeding programs is challenging in microplots, as ceptometer measurements are labor-intensive and limit scalability. Drones equipped with multispectral sensors provide an alternative approach for fIPAR estimation. This study aimed to estimate fIPAR in maize hybrids and inbred lines using simple regression models based on green canopy cover and 60 multispectral indices. Models differed between hybrids and inbred lines ($p < 0.05$). Green canopy cover was the best predictor (hybrids: $R^2 = 0.93$, RMSE = 0.09, NRMSE = 8.9%; lines: $R^2 = 0.86$, RMSE = 0.09, NRMSE = 10.3%). Among spectral indices commonly used in satellite applications, OSAVI showed the best performance in hybrids ($R^2 = 0.88$, RMSE = 0.107, NRMSE = 11.1%), whereas GNDVI performed best in lines ($R^2 = 0.85$, RMSE = 0.096, NRMSE = 10.8%). NDVI also explained a high proportion of fIPAR variability ($R^2=0,88$; RMSE=0,11; nRMSE=11,3% and $R^2=0,84$; RMSE=0,10; nRMSE=11%, respectively). These results highlight the potential of RGB images for low-cost fIPAR estimation using green canopy cover, while spectral indices could support satellite-based estimation at larger scales.

Palabras clave: sensores remotos, VANT, *Zea mays*, cobertura

Keywords: remote sensing, UAV, *Zea mays*, canopy cover

INTRODUCCIÓN

El análisis de la radiación fotosintéticamente activa absorbida (RFAA) es fundamental en el estudio de la ecofisiología de cultivos, dado su vínculo directo con la tasa de crecimiento y, consecuentemente, con la determinación del número de granos y el rendimiento final del maíz (*Zea mays* L.) (Cirilo et al., 2023; Monteith, 1977). La



estimación de la RFAA requiere conocer la radiación fotosintéticamente activa incidente y la fracción de radiación fotosintéticamente activa interceptada (fRFAI), la cual es equivalente a la fracción de la radiación activa absorbida (fRFAA) (Andrieu & Baret, 1993; Liu et al., 2021). En consecuencia, la fRFAI constituye una variable de gran interés y presenta una elevada variabilidad, asociada tanto a factores genotípicos, como la arquitectura foliar, el largo del ciclo y la disposición de las hojas, como a prácticas de manejo, entre ellas la densidad de siembra, el distanciamiento entre hileras y la fecha de siembra.

Frente a la dificultad de medir estas variables a campo, la teledetección surge como una alternativa eficaz para estimar la fRFAI. A nivel satelital, esto se ha logrado mediante diversos índices de vegetación (NDVI, NDRE, GNDVI) en distintos cultivos (Gitelson, 2019; Gitelson et al., 2014). Entre las limitaciones de las estimaciones satelitales se destaca la baja resolución espacial de las imágenes, que impide discriminar ensayos de microparcels y dificulta la eliminación de la interferencia del suelo en las estimaciones de fRFAI realizadas durante las etapas tempranas del cultivo.

Asimismo, las regresiones basadas en índices suelen presentar mayores errores cuando se aplican en distintas regiones geográficas, ya que ignoran los efectos de la latitud regional y de la estructura local del dosel, lo que puede generar errores de estimación de hasta un 40 % (Huemmrich, 2013). Por último, cada sensor opera con una resolución espectral propia, lo que introduce variaciones en el cálculo de un mismo índice. Por otra parte, la resolución espacial de cada plataforma también puede generar diferencias en la respuesta obtenida. En consecuencia, la transferencia de modelos entre regiones o sensores resulta limitada.

En los estudios ecofisiológicos, las mediciones terrestres tradicionales se realizan con ceptómetros, los cuales son altamente precisos para evaluar fRFAI en microparcels experimentales, pero su alta demanda operativa limita su aplicación en ensayos masivos. Además, estas determinaciones pueden verse afectadas por la subjetividad del operador al aplicar distintos criterios de medición. En este sentido, los drones equipados con sensores multiespectrales surgen como la herramienta ideal para superar esta restricción de escala (Gano et al., 2024). Su uso permite estimar variables biofísicas de forma simultánea en cientos o miles de microparcels, eliminando las dificultades operativas, temporales y el alto costo en tiempo que implica realizar las mediciones de manera manual (Bhandari et al., 2023; Tattaris et al., 2016).

Las cámaras multiespectrales en drones permiten adquirir imágenes con alta resolución espacial y espectral, lo que posibilita caracterizar el cultivo con un elevado nivel de detalle. A partir de estas imágenes es posible calcular índices de vegetación que capturan atributos relacionados con el vigor, el contenido de clorofila y la estructura del canopeo. Sin embargo, numerosos índices espectrales presentan saturación a elevados valores del índice de área foliar (Gitelson et al., 2014). Asimismo, la alta resolución espacial de estas imágenes permite cuantificar con precisión la cobertura verde, un indicador estructural estrechamente asociado con la intercepción de radiación por el cultivo.

Adicionalmente, los algoritmos desarrollados para condiciones generales suelen presentar un desempeño limitado cuando se aplican en microparcels o cultivos específicos. En este sentido, Pellegrini et al. (2020) detectaron fuertes sesgos utilizando índices diseñados para múltiples tipos de vegetación (*Sentinel-2 Toolbox*) en trigo, y

demonstraron que los sensores de proximidad como el *GreenSeeker* logran modelos mucho más precisos. Esto evidencia la necesidad de calibrar localmente los modelos de regresión, ya que la arquitectura específica de cada cultivo altera significativamente la reflectancia.

Hasta donde sabemos, no existen en el país relaciones empíricas entre la fRFAI del maíz y la información derivada de sensores multispectrales en drones o satélites. En este contexto, el objetivo de este trabajo fue estimar la fRFAI en híbridos y líneas de maíz mediante modelos de regresión basados en la cobertura verde del dosel y en índices de vegetación derivados de imágenes multispectrales.

Para alcanzarlo, se plantearon los siguientes objetivos específicos:

- Comparar modelos de regresión simple (lineal, exponencial y logístico) para identificar qué índices espectrales evitan el efecto de saturación del dosel.
- Evaluar si los modelos de regresión simple difieren significativamente entre híbridos, líneas y la etapa fenológica (vegetativa vs. reproductiva).

MATERIALES Y MÉTODOS

El experimento se realizó durante la campaña 2024/2025 en el campo experimental de la Estación Experimental Agropecuaria INTA Pergamino (33°57'35.4"S 60°34'08.8"W). Se evaluaron nueve híbridos experimentales y once líneas de maíz bajo un diseño de bloques completos al azar con tres repeticiones. Las unidades experimentales consistieron en microparcels de cuatro surcos, establecidas con una densidad de siembra de 8 pl/m² y riego suplementario por aspersión. Los genotipos presentaban arquitecturas foliares contrastantes, desde fenotipos planófilos hasta erectófilos, lo que permitió analizar el efecto de la arquitectura del dosel sobre la intercepción de radiación y la respuesta espectral.

Adquisición y procesamiento de imágenes: Los vuelos se realizaron a 20 m de altura con 75% de superposición (lateral y frontal), bajo cielo despejado y en torno al mediodía solar (± 1 h). Tras la calibración radiométrica con un panel MicaSense previo y posterior a cada vuelo, las imágenes se procesaron en *Agisoft Metashape* para generar ortomosaicos de 8,44 mm/píxel de resolución espacial (Figura 1).



Figura 1. Adquisición y procesamiento de imágenes en Metashape para generar ortomosaicos.

Los ortomosaicos fueron analizados mediante el software libre QGIS (QGIS Development Team, 2023). El sensor utilizado permitió capturar imágenes en seis bandas espectrales: azul (475 nm), verde (560 nm), rojo (668 nm), borde rojo (717 nm), e infrarrojo cercano (840 nm). Para evitar el efecto de borde, se delimitaron regiones de interés (ROI) de forma automatizada para cada parcela con el complemento *Magic Microplots Shape Generator* (Menes, 2026). Se generaron áreas de 1,00 m de largo por 0,70 m de ancho, posicionadas sobre el área central de un solo surco por parcela. A

partir de estas áreas, se extrajo el valor de la mediana de los píxeles de cada banda espectral, lo que permitió calcular 60 índices con distintas combinaciones. Adicionalmente, se determinó la cobertura verde (en una escala de 0 a 1) calculando el porcentaje de área foliar verde por ROI (Fig. 2). Para ello, se excluyeron los píxeles correspondientes a suelo y material senescente mediante una máscara basada en un umbral de 0 utilizando el índice de tono general (HUE) obtenido a partir de las bandas RGB (Ec. 1) (Matias et al., 2020).

$$\text{HUE} = \arctan \left(\frac{2 \cdot (\text{Azul} - \text{Verde} - \text{Rojo})}{30,5 \cdot (\text{Verde} - \text{Rojo})} \right) \quad (\text{Ec. 1})$$




Figura 2. Flujo de trabajo. Izquierda: extracción de reflectancia e índices espectrales en las ROI. Derecha: cálculo de cobertura verde aislando suelo y senescencia mediante el índice HUE.

Verdades de terreno: La fRFAI se midió a campo mediante un ceptómetro de un metro de longitud (Cavadevices, 400-700 nm) bajo condiciones de cielo despejado y en torno al mediodía solar, con un desfase máximo de cuatro días respecto de los vuelos (Figura 3), abarcando desde el estadio V5 hasta la madurez fisiológica. En cada microparcela se realizaron cuatro lecturas por debajo del dosel, posicionando la barra del ceptómetro en diagonal entre los surcos. La radiación incidente se estimó mediante la media de ocho lecturas por encima del dosel, realizadas antes y después de evaluar aproximadamente 12 microparcels. Durante la senescencia del cultivo, las mediciones inferiores se efectuaron a la altura de la última hoja verde para excluir el tejido senescente. Finalmente, los valores de fRFAI se interpolaron linealmente para sincronizarlos temporalmente con las fechas de vuelo.



50 AÑOS
PENSANDO
EL FUTURO

XIII
CONGRESO
NACIONAL
DE MAÍZ




Figura 3. Línea temporal expresado en días desde la siembra (DDS). Se detallan los momentos de evaluación mediante fotogrametría con un dron (azul) y las mediciones terrestres de la fRFAI utilizando ceptómetro (naranja).

Además, se registró la fenología mediante el seguimiento de cinco plantas marcadas por microparcela. Esto permitió separar el ciclo en fase vegetativa y reproductiva a partir de la aparición de estigmas visibles, correspondiente al estadio R1 (Ritchie et al., 1986)

Análisis estadístico: Se evaluaron modelos de regresión simple (lineales, exponenciales y logísticos) que relacionaron la fRFAI con la cobertura verde y cada uno de los 60 índices multispectrales. Para cada variable predictora, el análisis se realizó de forma global (híbridos y líneas) y luego de manera independiente para cada grupo genético. Finalmente, se analizó si el ajuste de los modelos mejoraba al discriminar los datos según la fase fenológica del cultivo (vegetativa y reproductiva).

Los modelos se evaluaron mediante el coeficiente de determinación (R^2), la raíz del error cuadrático medio (RMSE) y la raíz del error cuadrado medio normalizada (nRMSE, %). Para evaluar si la separación de modelos por grupo genético (híbridos y líneas) era estadísticamente significativa, se realizó una prueba ANCOVA (F-Test) sobre los modelos. Para representar la condición de suelo desnudo (fRFAI = 0), se delimitaron 50 ROI de $1 \times 0,7$ m sobre áreas sin vegetación. Para cada ROI se extrajo la mediana de reflectancia de cada banda y luego se promediaron las medianas de los 50 ROI para obtener el valor medio de cada banda, a partir del cual se calcularon los mismos 60 índices espectrales.

RESULTADOS Y DISCUSIÓN

La cobertura verde resultó ser la variable más robusta para predecir la fRFAI (Fig. 4), aunque con diferencias en el modelo óptimo siendo lineal para los híbridos con un $R^2=0,92$, RMSE=0,086, nRMSE=8,9% y logístico para las líneas con $R^2=0,86$, RMSE=0,092 y nRMSE=10,3%. El modelo lineal en líneas tuvo un comportamiento similar con un $R^2=0,86$ y con los mismos valores de RMSE que el modelo logístico (Figura 4). Los modelos ajustados para híbridos y líneas difirieron significativamente ($p < 0,05$), lo que justificó el empleo de regresiones específicas para cada grupo. En contraste, la separación de los datos según la etapa fenológica deterioró el ajuste de los modelos correspondientes a la fase reproductiva (R^2 y RMSE).




Figura 4. Modelos (lineal y logístico) de fRFAI vs. cobertura verde en maíz. Ajustes para híbridos, líneas y modelo global. Símbolos: fases vegetativas (círculos) y reproductivas (triángulos).

Esta elevada capacidad predictiva se explica porque, al excluir el fondo de suelo y la vegetación senescente, la cobertura verde cuantifica la fracción del terreno ocupada por tejido fotosintéticamente activo, estrechamente vinculada con la fracción de radiación interceptada por el dosel. Como señalan Huemmrich (2013), la intercepción de la radiación está determinada principalmente por atributos estructurales del cultivo, como la arquitectura del dosel y la disposición espacial de las hojas. En este contexto, la cobertura verde estimada mediante drones constituye una medida espacial de dicha estructura, libre de la influencia del suelo y del tejido senescente.

Los índices espectrales de mejor desempeño lograron alcanzar una precisión predictiva comparable a la estimación de la cobertura (Tabla 1). En el caso de los híbridos, el mejor modelo luego del de cobertura resultó ser la regresión lineal basada en el índice OSAVI ($R^2=0,88$ $RMSE=0,107$, $nRMSE=11,1$). La efectividad de este índice radica en su factor de corrección por suelo, lo cual resulta fundamental para mitigar la interferencia que ejercen las propiedades ópticas del fondo sobre el dosel. Por su parte, en las líneas, el ajuste más preciso se obtuvo mediante un modelo logístico utilizando el índice GNDVI ($R^2=0,85$ $RMSE=0,096$, $nRMSE=10,8$). El GNDVI se fundamenta en que, al utilizar la banda verde en lugar de la roja como en el NDVI, el coeficiente de absorción de la clorofila es drásticamente menor (solo 1-2% del registrado en el rojo), lo que incrementa el recorrido de la luz dentro del canopeo y mejora significativamente la sensibilidad del índice en canopeos densos (Gitelson, 2019).

En el análisis también se incluyó el NDVI, debido a su amplio uso como índice de referencia en la literatura. Si bien no integró el grupo de los mejores predictores de la fRFAI, su ajuste fue también muy alto, con diferencias de escasa magnitud respecto de los índices de mejor desempeño. En las líneas el mejor ajuste fue lineal ($R^2=0,84$; $RMSE=0,10$; $nRMSE=11\%$), mientras que en los híbridos fue logístico ($R^2=0,88$; $RMSE=0,11$; $nRMSE=11,3\%$). Este comportamiento podría explicarse por la saturación de la banda roja en doseles densos, particularmente en híbridos, donde el rápido

desarrollo del área foliar incrementa la no linealidad de la relación entre el índice y la fRFAI.

El buen desempeño del modelo basado en la cobertura verde del dosel como variable predictora demuestra que la fRFAI puede estimarse con alta precisión incluso mediante sensores RGB de bajo costo. Esta aproximación reduce la dependencia de mediciones con ceptómetros y de las condiciones de iluminación requeridas tanto para las evaluaciones manuales como para la adquisición de información espectral.

Tabla 1. Ecuaciones de regresión para estimar la fRFAI en híbridos y líneas de maíz utilizando los dos mejores índices y el NDVI (referencia). IR: infrarrojo cercano.

Índice	Fórmula	Modelo	R ²	RMSE	NRMSE (%)	Ecuación
HÍBRIDOS (H)						
Cobertura	$\frac{N^{\circ} \text{ píxeles verdes}}{N^{\circ} \text{ píxeles totales}}$	Lineal	0,925	0,086	8,9%	$y = 0.0224 + 0.9433x$
OSAVI	$\frac{IR - Rojo}{IR + Rojo + 0,16}$	Lineal	0,884	0,107	11,1%	$y = -0.2145 + 1.5753x$
NDVI	$\frac{IR - Rojo}{IR + Rojo}$	Logístico	0,879	0,110	11,3%	$y = \frac{1.2404}{1 + e^{\frac{(0.7663 - x)}{0.1854}}}$
LÍNEAS (L)						
Cobertura	$\frac{N^{\circ} \text{ píxeles verdes}}{N^{\circ} \text{ píxeles totales}}$	Logístico	0,864	0,092	10,3%	$y = \frac{0.6921}{1 + e^{\frac{(0.3302 - x)}{0.1538}}}$
GNDVI	$\frac{IR - Verde}{IR + Verde}$	Logístico	0,849	0,096	10,8%	$y = \frac{0.6855}{1 + e^{\frac{(0.4977 - x)}{0.0798}}}$
NDVI	$\frac{IR - Rojo}{IR + Rojo}$	Lineal	0,843	0,098	11,0%	$y = -0.1101 + 0.9252x$

CONCLUSIONES

La cobertura verde del dosel resultó ser el mejor predictor de la fRFAI, superando a los 60 índices multispectrales evaluados. Entre estos, el OSAVI presentó el mejor desempeño en híbridos, mientras que el GNDVI fue el más preciso en líneas. Asimismo, el estudio demostró que es necesario ajustar modelos independientes para híbridos y líneas, debido probablemente a sus contrastantes arquitecturas foliares. En cambio, la diferenciación por etapa fenológica no mejoró el ajuste, indicando que un único modelo por tipo de material es robusto para todo el ciclo del cultivo.

Estos resultados demuestran que la fRFAI puede estimarse con alta precisión mediante sensores RGB de bajo costo a partir de la cobertura verde, reduciendo la dependencia de ceptómetros y de las condiciones de cielo despejado requeridas para las mediciones manuales. Esto permite evaluar un ensayo completo en pocos minutos, reduciendo significativamente los costos y la demanda de mano de obra, además de minimizar errores asociados a las variaciones de luz y viento durante el muestreo en terreno. En consecuencia, constituye una herramienta de gran utilidad para ensayos enfocados en la absorción de radiación y la eficiencia de uso de la radiación.

Finalmente, la calibración local de índices multispectrales obtenida mediante drones sienta las bases para escalar estas estimaciones a plataformas satelitales, posibilitando la estimación de grandes extensiones de la fRFAI y mejorando la predicción del rendimiento a gran escala mediante la ecuación de Monteith.

APOYO FINANCIERO: PROYECTO ESTRUCTURAL 2023-PE-L06-I081; PROYECTO DISCIPLINARIO 2023-PD-L01-I102; PROYECTO ESTRUCTURAL 2023-PE-L01-I110.

BIBLIOGRAFÍA

- Andrieu, B., & Baret, F. (1993). Indirect methods of estimating crop structure from optical measurements. *Crop Structure and Light Microclimate.*, 285–232.
- Bhandari, M., Chang, A., Jung, J., Ibrahim, A. M. H., Rudd, J. C., Baker, S., Landivar, J., Liu, S., & Landivar, J. (2023). Unmanned aerial system-based high-throughput phenotyping for plant breeding. *Plant Phenome Journal*, 6(1). <https://doi.org/10.1002/ppj2.20058>
- Cirilo, A., Andrade, F., & Valentinuz, O. (2023). Espaciamiento entre hileras del cultivo. In F. Andrade, M. E. Otegui, A. Cirilo, & S. Uhart (Eds.), *Ecofisiología y manejo del cultivo de maíz* (1a ed., pp. 245–274). Fernando Héctor Andrade.
- Gano, B., Bhadra, S., Vilbig, J. M., Ahmed, N., Sagan, V., & Shakoor, N. (2024). Drone-based imaging sensors, techniques, and applications in plant phenotyping for crop breeding: A comprehensive review. In *Plant Phenome Journal* (Vol. 7, Number 1). John Wiley and Sons Inc. <https://doi.org/10.1002/ppj2.20100>
- Gitelson, A. A. (2019). Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: generic algorithm for maize and soybean. *Remote Sensing Letters*, 10(3), 283–291. <https://doi.org/10.1080/2150704X.2018.1547445>
- Gitelson, A. A., Peng, Y., & Huemmrich, K. F. (2014). Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sensing of Environment*, 147, 108–120. <https://doi.org/10.1016/j.rse.2014.02.014>
- Huemmrich, K. F. (2013). Simulations of Seasonal and Latitudinal Variations in Leaf Inclination Angle Distribution: Implications for Remote Sensing. *Advances in Remote Sensing*, 02(02), 93–101. <https://doi.org/10.4236/ars.2013.22013>
- Liu, S., Baret, F., Abichou, M., Manceau, L., Andrieu, B., Weiss, M., & Martre, P. (2021). Importance of the description of light interception in crop growth models. *Plant Physiology*, 186(2), 977–997. <https://doi.org/10.1093/PLPHYS/KIAB113>
- Matias, F. I., Caraza-Harter, M. V., & Endelman, J. B. (2020). FIELDImageR: An R package to analyze orthomosaic images from agricultural field trials. *Plant Phenome Journal*, 3(1). <https://doi.org/10.1002/ppj2.20005>
- Menes, J. F. (2026). *Magic Microplots Shape Generator – UAV* (0.01). Zenodo. <https://doi.org/10.5281/zenodo.18231789>
- Monteith, J. L. (1977). Climate and the efficiency of crop production in Britain. *Philosophical Transactions of the Royal Society of London. B, Biological Sciences*, 281(980), 277–294. <https://doi.org/10.1098/rstb.1977.0140>
- Pellegrini, P., Cossani, C. M., Di Bella, C. M., Piñeiro, G., Sadras, V. O., & Oesterheld, M. (2020). Simple regression models to estimate light interception in wheat crops with Sentinel-2 and a handheld sensor. *Crop Science*, 60(3), 1607–1616. <https://doi.org/10.1002/csc2.20129>
- QGIS Development Team. (2023). *QGIS Geographic Information System* (3.34.0.). <http://qgis.org>
- Ritchie, S. W., Hanway, J. J., & Benson, G. O. (1986). *How a Corn Plant Develops. Spec. Rep. 48:24.*
- Tattaris, M., Reynolds, M. P., & Chapman, S. C. (2016). A direct comparison of remote sensing approaches for high-throughput phenotyping in plant breeding. *Frontiers in Plant Science*, 7(AUG2016). <https://doi.org/10.3389/fpls.2016.01131>