



RESEARCH ARTICLE

Remote sensing of rice yield using UAV-derived SAVI and supervised machine learning models in Tropical Lowlands

Teledetección del rendimiento del arroz mediante el índice SAVI obtenido con drones y modelos de aprendizaje automático supervisado en zonas bajas tropicales

Alfredo Ysuiza-Perez¹ ; Mónica Perez-Tello¹ ; Diego Goigochea-Pinchi¹ ; Sergio Vega-Herrera¹ ; Raúl Rios-Rios¹ ; Percy Dominguez-Yap¹ ; Leonela García¹ ; Cicerón Barrera-Torres¹ ; Carlos Oliva-Cruz^{1*} ; Manuel Santillán-González¹ ; David Arratea-Pillco² ; Italo W. Alejos-Patiño³ 

¹ Estación Experimental Agraria El Porvenir. Instituto Nacional de Innovación Agraria (INIA). Carretera Marginal Sur Fernando Belaunde Terry S/N. Juan Guerra 22400. San Martín, Perú.

² Universidad Nacional Autónoma de Alto Amazonas (UNAAA). Prolongación Libertad 1220. Yurimaguas 16501. Loreto, Perú.

³ Universidad Nacional Hermilio Valdizán (UNHEVAL), Av. Universitaria N° 601-607, Pillco Marca 10003, Huánuco, Perú.

* Corresponding author: coliva@inia.gob.pe (C. Oliva-Cruz).

Received: 7 October 2025. Accepted: 5 April 2026. Published: 27 April 2026.

Abstract

Accurate estimation of rice productivity at the sub-field level is still a major challenge in tropical agroecosystems, mainly because of the high spatial variability and the limits of traditional monitoring methods. This study looked at how well the soil-adjusted vegetation index (SAVI), pulled from multispectral images taken by UAVs, could separate productive and non-productive zones in rice fields under tropical lowland conditions in San Martín, Peru. We used a randomized complete block design across two locations with three rice varieties and captured multispectral images at key phenological stages using UAV platforms. Field yield came from georeferenced destructive sampling—we adjusted grain weight to standard moisture and expressed everything in $t\ ha^{-1}$. Based on those actual measurements, we set threshold criteria to classify zones as either productive or non-productive. SAVI values were then extracted and fed into supervised classification models: logistic regression, support vector machine (SVM), k-nearest neighbors (KNN), random forest, and decision tree. The results showed that SAVI values between 0.50 and 0.70, typically lined up with productive zones, while 0.30 to 0.50 corresponded to non-productive areas. Logistic regression and SVM came out on top with overall accuracy around 88.9%, F1-scores above 92%, and pretty balanced sensitivity and specificity. These findings suggest that combining SAVI with supervised machine learning offers a solid, practical way to map rice productivity spatially. The approach looks promising for supporting intra-field monitoring and helping make better agronomic decisions in tropical rice systems.

Keywords: precision agriculture; UAV multispectral imagery; rice yield estimation; SAVI index; supervised classification; logistic regression; support vector machines.

Resumen

La estimación de la productividad del arroz dentro de una misma parcela es un desafío en los agroecosistemas tropicales, por la alta variabilidad espacial y limitaciones en los métodos tradicionales de monitoreo. El objetivo del estudio fue evaluar la capacidad del índice de vegetación ajustado al suelo (SAVI, soil-adjusted vegetation index) derivado de imágenes multiespectrales obtenidas mediante vehículos aéreos no tripulados (UAV, unmanned aerial vehicles) para diferenciar las zonas productivas de las que no lo son en parcelas arroceras de selva baja tropical, en la región San Martín, Perú. Se usó un diseño de bloques completos al azar en dos localidades, con tres variedades de arroz, y se tomaron imágenes multiespectrales usando plataformas UAV. El rendimiento real de campo se midió con muestreo destructivo georeferenciado, ajustando el peso del grano a una humedad estándar y expresándolo en toneladas por hectárea. Con esos datos, las parcelas se clasificaron en zonas productivas y no productivas según criterios de umbral obtenidos de las mediciones directas. Después se extrajeron los valores de SAVI y se usaron como variable de entrada en varios modelos de clasificación supervisada: regresión logística, máquinas de soporte vectorial (SVM), k vecinos más cercanos (KNN), bosque aleatorio y árbol de decisión. Los resultados mostraron que los valores de SAVI entre 0,50 y 0,70 se relacionaban con las zonas productivas, mientras que los que estaban entre 0,30 y 0,50 correspondían a las no productivas. La regresión logística y el SVM fueron los que mejor rindieron, con una exactitud global del 88,9%, valores de F1 por encima del 92% y un balance adecuado entre sensibilidad y especificidad. Esto demuestra que el SAVI con aprendizaje automático supervisado es una estrategia para discriminar espacialmente la productividad del arroz, con potencial para apoyar en el monitoreo dentro de la parcela y en las decisiones agronómicas en sistemas arroceros tropicales.

Palabras clave: agricultura de precisión; imágenes multiespectrales UAV; estimación de rendimiento de arroz; índice SAVI; clasificación supervisada; regresión logística; máquinas de soporte vectorial.

DOI: <https://doi.org/10.17268/sci.agropecu.2026.034>

Cite this article:

Ysuiza-Perez, Perez-Tello, M., Goigochea-Pinchi, D., Vega-Herrera, S., Rios-Rios, R., Dominguez-Yap, P., García, L., Barrera-Torres, C., Oliva-Cruz, C., Santillán-González, M., Arratea-Pillco, D., & Alejos-Patiño, I. W. (2026). Teledetección del rendimiento del arroz mediante el índice SAVI obtenido con drones y modelos de aprendizaje automático supervisado en zonas bajas tropicales. *Scientia Agropecuaria*, 17(2), 481-495.

1. Introducción

El arroz (*Oryza sativa* L.) es uno de los cultivos estratégicos para la seguridad alimentaria en todo el mundo, ya que aporta entre el 20% y el 25% de las calorías que se consumen globalmente. Y la demanda sigue subiendo por el aumento de la población y la urbanización, sobre todo en los países en desarrollo (Fukagawa & Ziska, 2019). En Perú, la producción de arroz cáscara llegó a 3,52 millones de toneladas en 2024, con un crecimiento anual del 4,2%, así que se mantiene como uno de los cultivos agrícolas más importantes tanto en volumen como en valor económico (MINAGRI, 2025). En este panorama, la región San Martín aporta alrededor del 24,5% de toda la producción nacional, con rendimientos promedio que andan cerca de las 7,8 t ha⁻¹. Es un sistema bastante intensivo en el trópico húmedo, pero pues enfrenta varios retos como es la variabilidad del clima, suelos que varían mucho de un lado a otro y dificultades para hacer un monitoreo agronómico (MINAGRI, 2025). Es así como la agricultura de precisión se vuelve cada vez más relevante para sacar el máximo provecho y optimizar la productividad, usando tecnologías que ayuden a entender y manejar esa variabilidad espacial y temporal del cultivo.

No obstante, el desafío técnico no se queda solo en estimar el rendimiento promedio de toda la parcela, es decir hay que capturar esa variabilidad que existe dentro de la misma parcela, con una resolución espacial bien fina, para poder detectar zonas de distinta productividad dentro de un mismo lote. Esta cuestión es especialmente complicada en los sistemas arroceros tropicales, donde se cruzan las condiciones del suelo y el clima, el manejo que se le da al cultivo y cómo avanza el desarrollo de la planta, generando patrones bastante irregulares difíciles de detectar mediante métodos convencionales. Además, la nubosidad tan típica de estas zonas tropicales hace que las imágenes satelitales ópticas escaseen bastante, y eso limita la continuidad de los análisis en el tiempo. Pues en este panorama, los vehículos aéreos no tripulados "UAV" (Unmanned Aerial Vehicles) permiten tomar imágenes multiespectrales de alta resolución, normalmente entre 5 y 10 cm por píxel, con mucha más flexibilidad en cuanto a cuándo y cómo volar. Por eso se vuelven herramientas ideales para monitorear el cultivo con detalle, y entre los índices espectrales, el SAVI (Soil Adjusted Vegetation Index) ha mostrado ser especialmente útil en situaciones donde el suelo influye bastante, porque mejora la sensibilidad respecto a índices más clásicos como el NDVI, sobre todo cuando la

cobertura vegetal no es completa o es muy heterogénea (Peticiã et al., 2025; Zhang et al., 2025a).

El avance reciente de la teledetección con UAV ha hecho posible incluir información espectral, estructural y climática en modelos de predicción de rendimiento que usan aprendizaje automático. Liang et al. (2025) desarrollaron modelos para predecir el rendimiento del arroz con 69 índices de vegetación tomados en diferentes momentos, más variables meteorológicas, y lograron un R² de 0,83 usando Extreme Gradient Boosting. Eso demuestra que integrar variables ambientales puede mejorar la precisión entre un 10,7% y un 12,9% comparado con los modelos que solo usan índices espectrales. Por otro lado, Quille et al. (2025) en condiciones del norte del Perú encontraron que juntar índices espectrales con texturales sacados de UAV les permitió llegar a un R² de hasta 0,78 en las etapas más críticas del cultivo, y pues resaltan lo importante que es elegir bien el momento fenológico para estas predicciones. Y en sistemas un poco más complicados, Mena et al. (2025) mostraron que integrar datos de satélite, climáticos y de suelo mediante modelos de fusión multimodal puede alcanzar valores cercanos a R² = 0,80 a nivel de campo, lo que deja claro el potencial de estos enfoques integrados para afinar la predicción del rendimiento incluso a escala subparcelaria.

Además, estudios recientes han mostrado que elegir el modelo de aprendizaje automático no siempre se trata de ir por el más complejo, sino de ver cuál se ajusta mejor a los datos y a cómo está planteado el problema. Haseeb et al. (2025) que modelos lineales pueden dar resultados tan buenos como los no lineales cuando las variables predictoras mantienen relaciones bastante consistentes. Por su parte, Tripathi et al. (2025) encontraron que algoritmos como Random Forest logran errores de predicción de hasta 0,27 t ha⁻¹ en arroz usando índices sacados de sensores RGB baratos. En paralelo, Zhang et al. (2025a) y Gade et al. (2025) coinciden en que los modelos supervisados siguen siendo los más usados en cultivos como arroz, maíz y trigo, porque son robustos, fáciles de interpretar y se aplican bien en sistemas productivos de verdad. Bueno, estos hallazgos sugieren que, en contextos de agricultura tropical donde los datos suelen ser escasos y algo irregulares, modelos como Logistic Regression o Support Vector Machine (SVM) pueden tener ventajas claras en cuanto a estabilidad y a cómo se transfieren a otros casos. A pesar de estos avances, todavía queda un vacío científico importante en la Amazonia peruana.

La evidencia que hay no alcanza para decir con claridad si el SAVI sacado de imágenes UAV realmente logra distinguir de forma consistente esos patrones de productividad dentro de la misma parcela en arroz, bajo condiciones de selva baja tropical. Tampoco está claro si modelos supervisados de complejidad moderada pueden mantener un rendimiento sólido cuando hay tanta variabilidad ambiental y heterogeneidad espacial. Además, la gran mayoría de los estudios se han hecho en contextos agroecológicos de Asia, Europa o América del Norte, con muy poca validación en sistemas productivos amazónicos, donde cosas como la humedad alta, la nubosidad constante y el tipo de manejo agronómico crean condiciones bastante distintas (Gade et al., 2025; Saha et al., 2025). Pues este vacío limita bastante la transferencia tecnológica y que se

adopten de verdad las herramientas de agricultura de precisión en regiones tropicales como esta.

El objetivo del estudio fue evaluar hasta qué punto el índice SAVI, obtenido de imágenes multiespectrales tomadas con UAV, junto con algoritmos de clasificación supervisada, permite distinguir y mapear zonas productivas y no productivas dentro de parcelas arroceras en selva baja tropical, manteniendo relación con el rendimiento que realmente se midió en campo.

2. Metodología

El estudio se desarrolló en la región San Martín, ubicada en la selva baja del noreste peruano, en dos zonas representativas del sistema arrocero regional: Juan Guerra, en la provincia de San Martín, y San Hilarión, en la provincia de Picota (Figura 1).

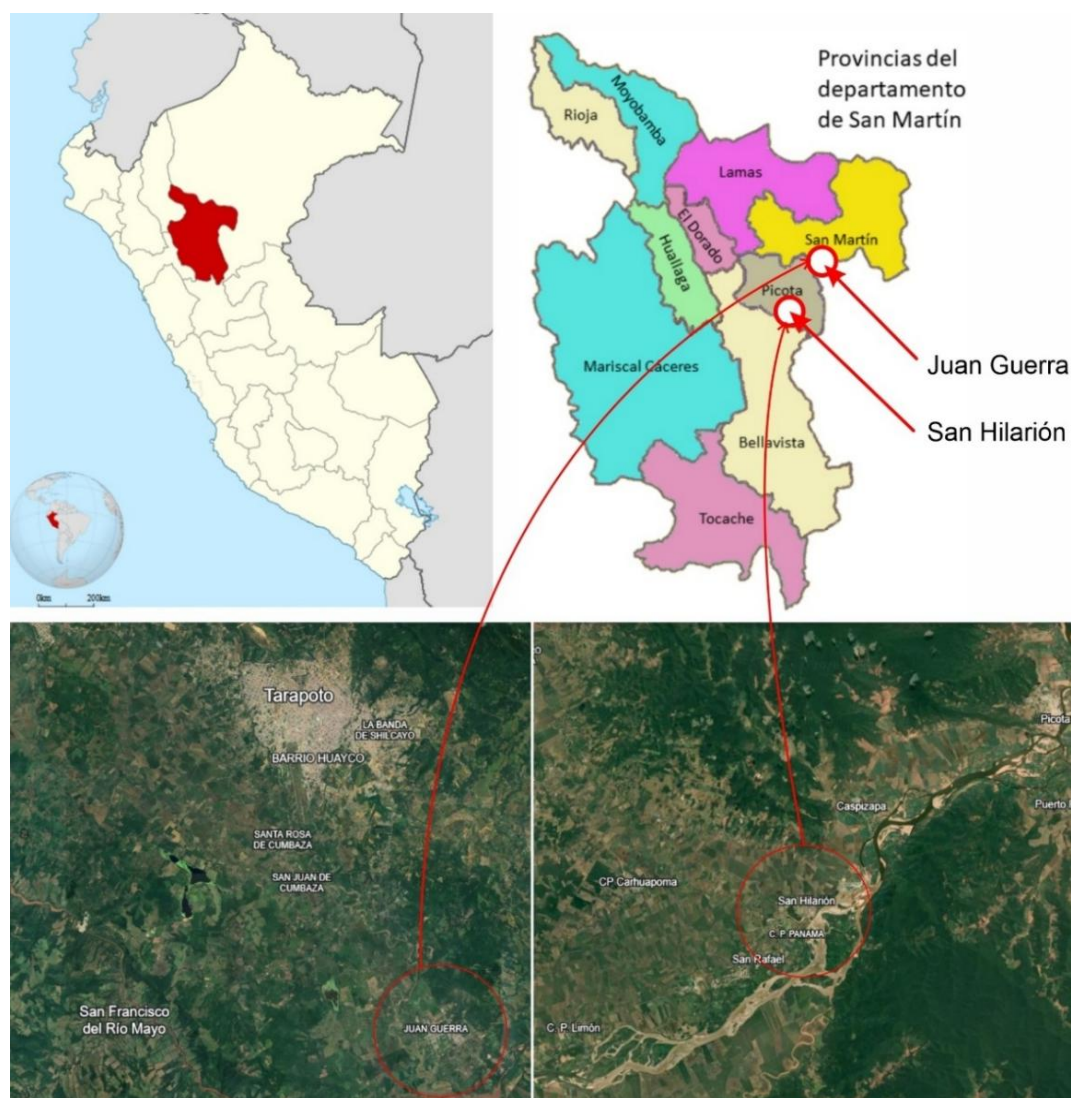


Figura 1. Localización geográfica del área de estudio en el Perú, región San Martín y zonas experimentales de Juan Guerra y San Hilarión.

Ambas localidades fueron seleccionadas por su importancia productiva dentro de los valles del Bajo Mayo y del Huallaga Central y por presentar condiciones contrastantes de altitud, drenaje y ambiente edáfico, adecuadas para evaluar la estabilidad de una metodología de teledetección aplicada al rendimiento del arroz (INIA, 2010). Juan Guerra se localiza a 330 m s. n. m., aproximadamente a 13 km de Tarapoto, sobre terrazas aluviales con suelos francos a franco arcillosos aptos para arroz bajo riego, mientras que San Hilarión se ubica a 195 m s. n. m. y presenta una matriz productiva influida por drenaje, pendiente y humedad edáfica. Asimismo, se señala que el área presenta alta humedad atmosférica, nubosidad estacional y temperaturas medias de 24 a 28 °C, rasgos típicos de la selva baja tropical que condicionan tanto el comportamiento del cultivo como la adquisición remota de datos (Senamhi, 2025).

El estudio se llevó a cabo en la región San Martín, en la selva baja del noreste peruano, y se enfocó en dos zonas representativas del sistema arrocero de la zona: Juan Guerra, que está en la provincia de San Martín, y San Hilarión, en la provincia de Picota. Las dos localidades se eligieron por su peso productivo en los valles del Bajo Mayo y del Huallaga Central, y porque presentan condiciones contrastantes en altitud, drenaje y tipos de suelo, lo que las hace ideales para analizar si una metodología de teledetección se mantiene estable al evaluar el rendimiento del arroz (INIA, 2010). Juan Guerra está a 330 m s. n. m., aprox. a 13 km de Tarapoto, sobre terrazas aluviales con suelos francos a franco arcillosos que funcionan para arroz con riego. En cambio, San Hilarión se ubica a 195 m s. n. m. y tiene

una matriz productiva más marcada por el drenaje, las pendientes y la humedad del suelo. En toda el área hay alta humedad atmosférica, nubosidad que varía según la estación y temperaturas medias entre 24 y 28 °C, que son rasgos típicos de la selva baja tropical y que influyen tanto en cómo se comporta el cultivo como en la toma de datos remotos (Senamhi, 2025).

Diseño experimental y material vegetal

Se empleó un diseño de bloques completos al azar con tres repeticiones por tratamiento, adecuado para controlar la heterogeneidad espacial dentro de cada localidad y comparar el comportamiento agronómico y espectral de tres variedades de arroz desarrolladas por el Instituto Nacional de Innovación Agraria: INIA 507 La Conquista, INIA 509 La Esperanza e INIA 516 LM1 La Unión 23. El factor de tratamiento correspondió a la variedad, mientras que el bloque representó la repetición espacial dentro de cada localidad. El diseño se aplicó por sitio, de modo que cada localidad constituyó un entorno agroecológico diferenciado y la comparación entre sitios se realizó posteriormente como contraste espacial entre ambientes, no como un solo experimento homogéneo. En total se establecieron nueve parcelas experimentales, con superficies comprendidas entre 40,14 y 60,98 m², georreferenciadas para garantizar la coincidencia espacial entre el muestreo de campo y la información multispectral. Las labores agronómicas, incluyendo fertilización, riego y control de malezas, se unificaron de acuerdo con la guía técnica institucional, con el fin de reducir fuentes de variación no experimental entre parcelas y fortalecer la interpretabilidad de la respuesta varietal y espectral (Figura 2).

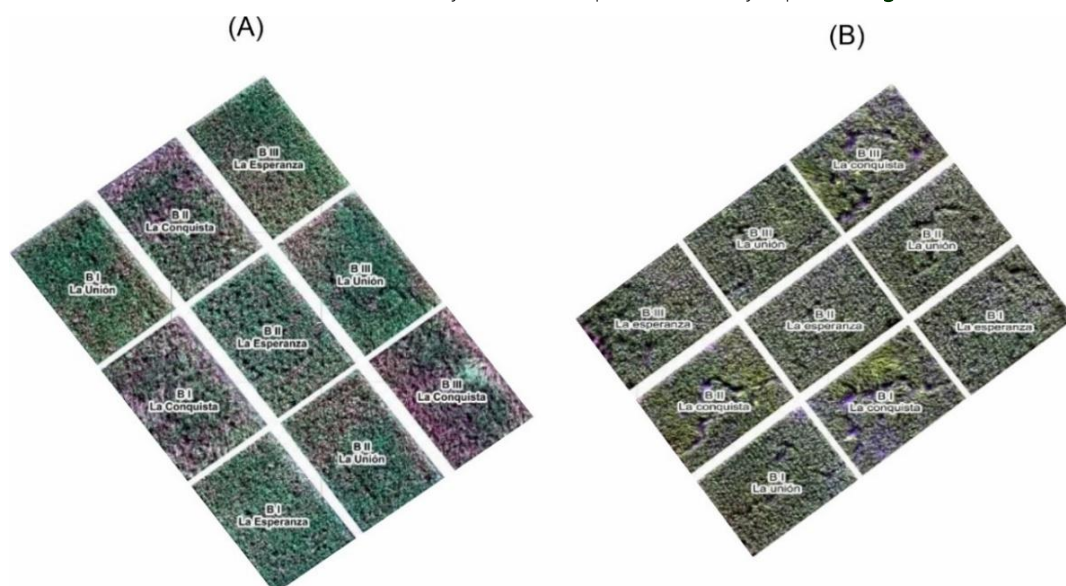


Figura 2. Diseño experimental de las parcelas de arroz en los distritos de Juan Guerra (A) y San Hilarión (B).

Adquisición de imágenes UAV

La adquisición de datos remotos se realizó con un cuadricóptero DJI Matrice 300 RTK equipado con el sistema dual MicaSense RedEdge MX y RedEdge MX Blue, capaz de registrar diez bandas espectrales centradas en 444, 475, 531, 560, 650, 668, 705, 717, 740 y 842 nm. Esta configuración cubre la región visible, el borde rojo y el infrarrojo cercano, lo que la hace apropiada para generar índices de vegetación sensibles al vigor del cultivo, contenido de clorofila y respuesta del dosel (Avtar et al., 2020; Barjaktarovic et al., 2024; Neupane & Baysal-Gurel, 2021). La planificación de vuelo se efectuó en DJI Pilot 2, con una altura de 30 m, velocidad de 4,5 m s⁻¹, traslape longitudinal y lateral del 80%, y ventanas de operación entre las 11:00 y 13:00 h, bajo velocidades de viento inferiores a 12 m s⁻¹. Con estos parámetros se obtuvo una resolución espacial final de 2,08 cm por píxel. Las tomas se distribuyeron a lo largo de 13 momentos distintos del ciclo del cultivo, lo que dio una serie temporal bastante densa para identificar patrones espectrales ligados a los cambios fenológicos y a la variación de productividad dentro de la misma parcela. Este enfoque va en línea con lo que se ve en la literatura reciente, que ha demostrado mejoras importantes en la predicción de rendimiento cuando se usan datos multitemporales de UAV en arroz y se eligen etapas críticas del desarrollo para el modelado. Por ejemplo, en China Liang et al. (2025) reportaron que integrar índices multitemporales con variables meteorológicas subió la precisión del modelo hasta R² = 0,83, mientras que Zhang et al. (2025a) concluyeron que los sensores multispectrales en UAV ya son una plataforma madura y consolidada para monitorear crecimiento, nutrición y rendimiento en agricultura de precisión.

Procesamiento radiométrico y generación de ortomosaicos

Las imágenes se procesaron con Pix4Dmapper Pro v4.8.0 y ArcGIS Pro, siguiendo un flujo de trabajo que incluyó calibración radiométrica, alineamiento fotogramétrico, ortorrectificación y la generación de ortomosaicos multispectrales de alta resolución. Se usaron nueve puntos de control terrestre georreferenciados con un receptor GNSS diferencial South Galaxy G1, lo que ayudó a mejorar bastante la precisión geométrica del mosaico y a garantizar la trazabilidad espacial en los análisis que vinieron después (Figura 3 y 4).

Cálculo de índices de vegetación

A partir de los ortomosaicos multispectrales se calcularon nueve índices de vegetación: NDVI, SAVI,

OSAVI, NDWI, NDRE, GNDVI, LCI, CIGreen y ReCL. Estos índices se evaluaron como variables derivadas del dosel para representar vigor, biomasa, clorofila y variación espacial del cultivo. El índice principal seleccionado para el modelado fue el Soil Adjusted Vegetation Index, calculado con un factor de corrección del suelo L = 0,5, según la formulación:

$$SAVI = \frac{(NIR - Red)}{(NIR + Red + L)}(1 + L)$$

donde NIR corresponde a la reflectancia del infrarrojo cercano, Red a la reflectancia del rojo y L al factor de corrección del efecto del suelo. La selección del SAVI se sustentó en su mayor robustez frente a fondos de suelo expuesto o coberturas vegetales incompletas, condición relevante en parcelas tropicales con heterogeneidad intra lote. Los índices ajustados por suelo mantienen valor operativo cuando existe interferencia espectral del fondo edáfico; Zhang et al. (2025a) señalan que SAVI, NDVI y GNDVI siguen siendo índices de uso maduro en agricultura de precisión, mientras que Quille et al. (2025) demostraron en Lambayeque, Perú, que la combinación de índices espectrales y texturales derivados de UAV mejora la predicción del rendimiento de arroz en etapas críticas del ciclo.

Muestreo de campo y cálculo del rendimiento de grano

La validación de campo se efectuó mediante muestreo destructivo en cada parcela experimental, con georreferenciación de las unidades de observación, a fin de vincular el rendimiento agrícola medido directamente con la información espectral. Se recolectaron muestras representativas por bloque y variedad registrándose pesos frescos y secos de espigas por unidad de superficie, expresando posteriormente el rendimiento en toneladas por hectárea. La variable REN1 corresponde al rendimiento bruto de campo y que REN2 corresponde al rendimiento ajustado a humedad estándar. La corrección del peso del grano a 14% de humedad es consistente con la práctica estándar para arroz reportada por IIRI, que establece que las mediciones de rendimiento deben expresarse a 14% de contenido de humedad para fines de comparabilidad. Primero se obtuvo el peso de grano cosechado por unidad de muestreo. Luego se midió el contenido de humedad del grano al momento del pesado. A continuación, el peso ajustado a 14 % de humedad se calculó mediante:

$$PG_{14} = PG \times \frac{86}{100 - MC}$$

donde PG_{14} es el peso del grano corregido a 14 % de humedad, PG es el peso observado del grano al momento del muestreo y MC es el contenido de humedad porcentual medido en campo.

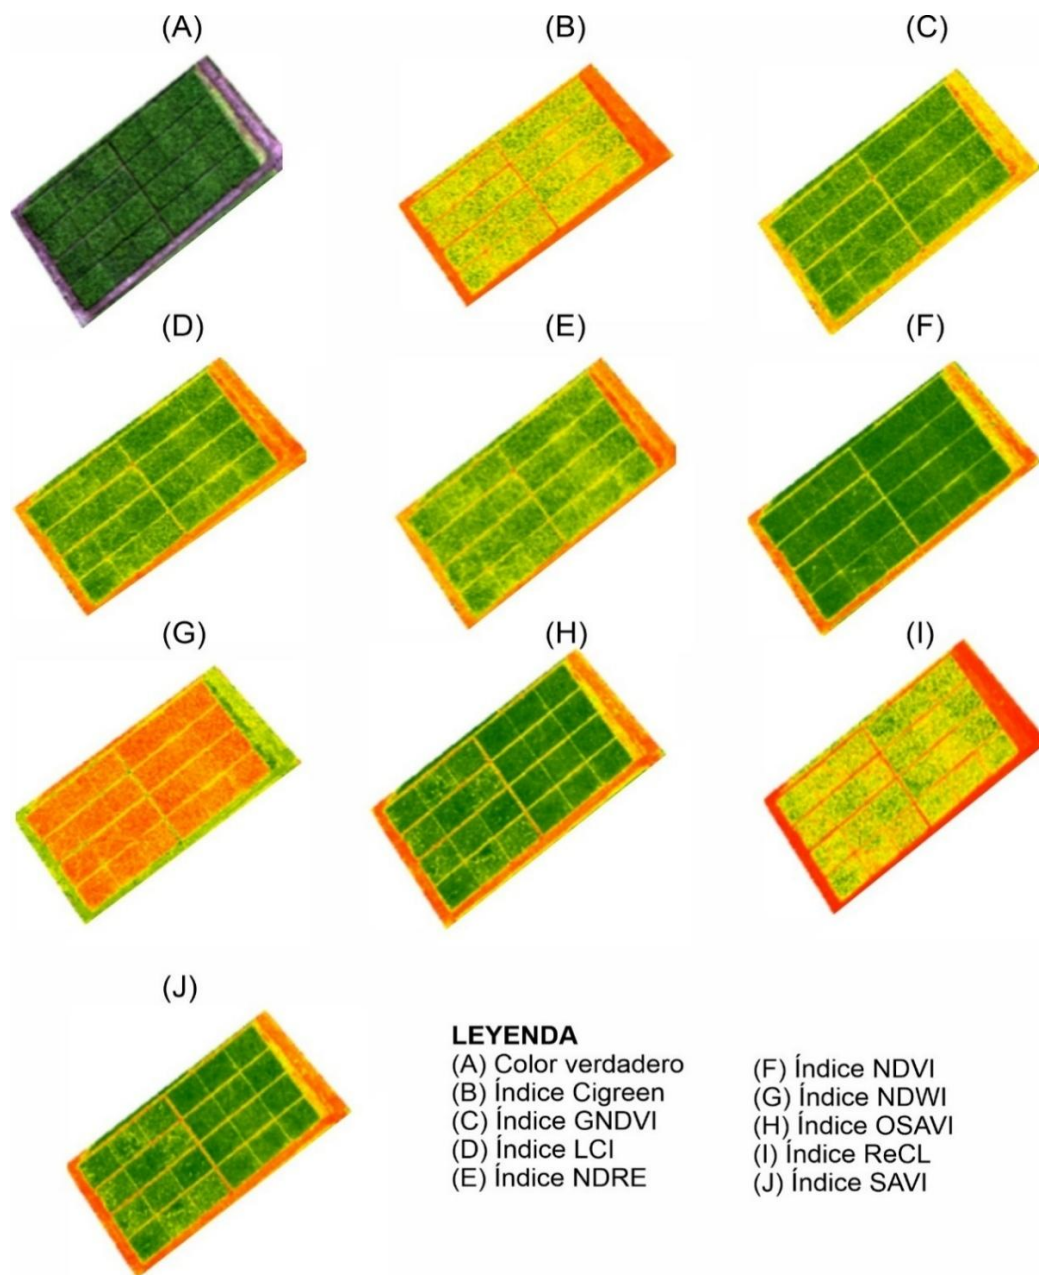


Figura 3. Imágenes multispectrales de las parcelas demostrativas de arroz en la EEA El Porvenir – Juan Guerra.

Posteriormente, el rendimiento ajustado en toneladas por hectárea se obtuvo con:

$$\text{Rendimiento (t ha}^{-1}\text{)} = \frac{PG_{14}}{A} \times 10$$

donde **A** es el área cosechada en m² y la constante 10 corresponde a la conversión de kg m⁻² a t ha⁻¹. Esta formulación coincide con los procedimientos estándar difundidos por IRRI para la corrección del rendimiento de arroz a humedad uniforme.

Construcción de la variable respuesta

La variable respuesta fue binaria y representó la condición de productividad de cada unidad espa-

cial analizada. La clasificación se realizó en dos clases: productiva y no productiva, y que la distribución del SAVI separó ambas clases con valores aproximados de 0,50 a 0,70 para áreas productivas y 0,30 a 0,50 para áreas no productivas. Dado que el total de registros superó los dos millones y la resolución fue de 2,08 cm por píxel, la unidad de clasificación fue, de manera consistente, el píxel del ortomosaico reclasificado. Para fortalecer la replicabilidad, conviene mencionar que la asignación de clase se hizo a partir de la correspondencia espacial entre los valores de SAVI y el rendimiento obser-

vado en campo, utilizando extracción del valor medio de SAVI en la zona georreferenciada de muestreo y posterior generación de etiquetas productiva o no productiva mediante una regla de decisión supervisada. Los píxeles o celdas con firma espectral asociada a áreas cuyos rendimientos ajustados se ubicaron por encima del centro de distribución del bloque fueron etiquetados como productivos, mientras que aquellos vinculados a rendimientos por debajo de dicho umbral fueron etiquetados como no productivos.

Con base en la **Tabla 2**, las áreas clasificadas como productivas oscilaron entre 51,71% y 92,10% según variedad, bloque y localidad, lo que confirma la existencia de heterogeneidad espacial suficiente para entrenar clasificadores binarios y justifica el

uso de métricas de desempeño más allá de la exactitud global.

Modelos de clasificación y validación

Se evaluaron cinco algoritmos de clasificación supervisada: Regresión Logística, Support Vector Machine, Random Forest, k nearest neighbors y Árbol de Decisión, con el propósito de discriminar espacialmente zonas productivas y no productivas en parcelas de arroz a partir de información espectral derivada de UAV. La variable de entrada principal fue el valor del SAVI por unidad espacial, mientras que la variable respuesta fue una etiqueta binaria de productividad construida a partir del rendimiento de campo georreferenciado y su correspondencia espacial con el ortomosaico.

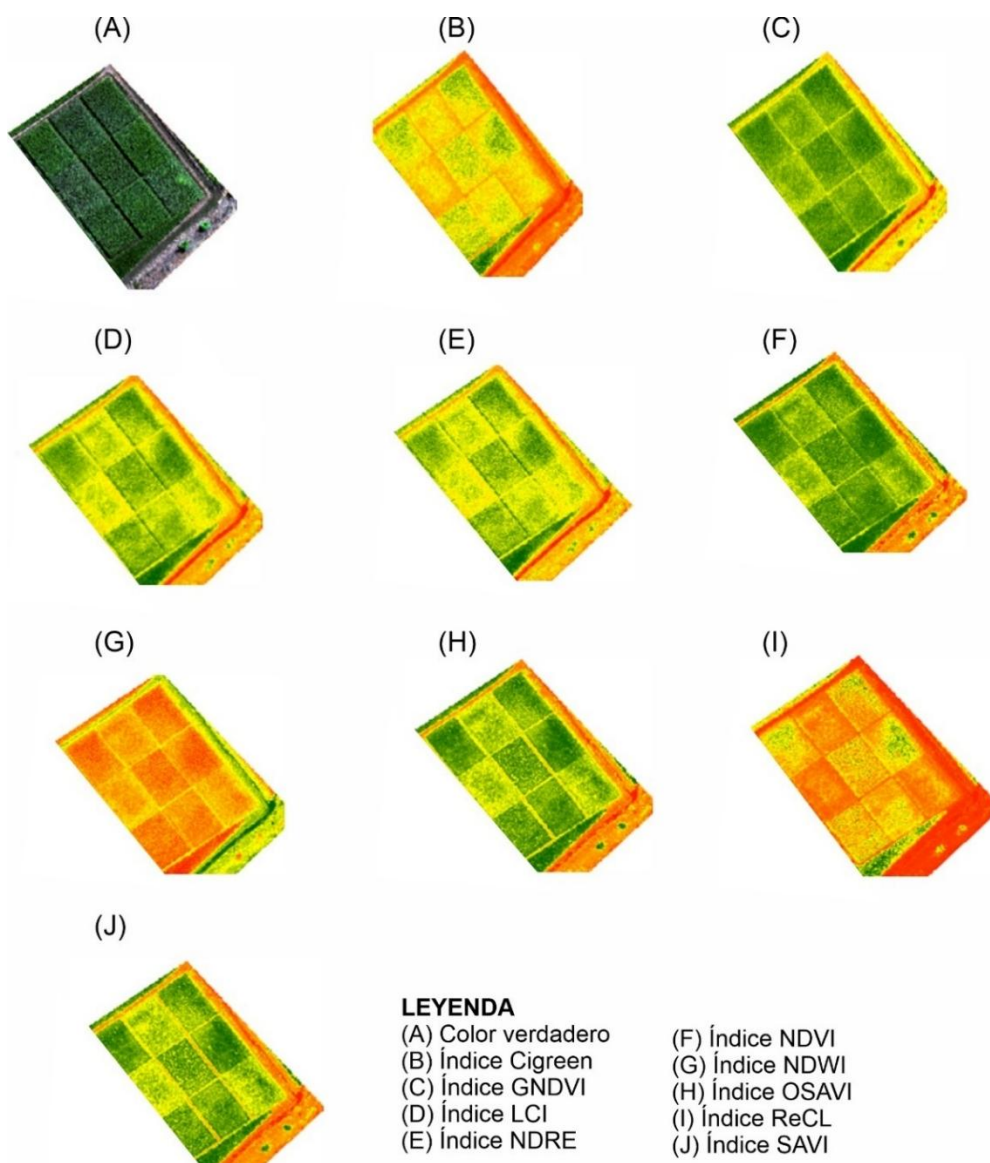


Figura 4. Imágenes multispectrales de las parcelas demostrativas de arroz en la EEA El Porvenir – San Hilarión.

En el flujo analítico completo se trabajó con un universo pixelado superior a dos millones de observaciones, mientras que las matrices de confusión corresponden a una evaluación sobre 698488 observaciones etiquetadas, con 534208 píxeles en la clase productiva y 164280 en la clase no productiva.

La selección de los clasificadores se basó en criterios tanto comparativos como operativos, considerando que modelos lineales y no lineales a veces dan resultados parecidos dependiendo de cómo estén estructurados los datos. **Liang et al. (2025)** lograron un R^2 de 0,83 con XGBoost en arroz, mientras que **Gade et al. (2025)** señalaron que los modelos supervisados siguen siendo los más usados, con Random Forest y los lineales como opciones bien robustas. Dado el desbalance de clases, la evaluación incluyó accuracy, precision, recall, specificity y F1 score, siguiendo lo que recomiendan (**Miftahshudur et al., 2025**). Al final, Regresión Logística y SVM fueron los que mostraron el mejor equilibrio, lo cual encaja perfecto con la naturaleza binaria del problema basado en SAVI.

Métricas de desempeño y análisis estadístico

El análisis estadístico se estructuró en dos niveles complementarios. El primero correspondió a la descripción agronómica del rendimiento por variedad, bloque y localidad. Para esta parte se emplearon medidas de tendencia central y dispersión, incluyendo media, desviación estándar, mínimo y máximo de REN1 y REN2, con el fin de caracterizar la variabilidad de la productividad entre materiales genéticos y ambientes. Esta síntesis permitió identificar la superioridad relativa de INIA 509 La Esperanza en ambas localidades y la mayor respuesta productiva de Juan Guerra frente a San Hilarión, resultados que luego se contrastaron con la distribución espacial del SAVI y con la proporción de área clasificada como productiva. El segundo nivel correspondió a la evaluación del desempeño de los clasificadores supervisados. Cada algoritmo se evaluó mediante accuracy, precision, recall, specificity y F1 score, además de la matriz de confusión individual.

Software

El procesamiento fotogramétrico y la generación de ortomosaicos se realizaron en Pix4Dmapper Pro v4.8.0, mientras que el procesamiento espacial, la reclasificación temática y la organización cartográfica se ejecutaron en ArcGIS Pro. El entrenamiento y la evaluación de los modelos de clasificación se

desarrollaron en Python 3.12, y el apoyo para estadística descriptiva, organización tabular y visualización complementaria se efectuó en R 4.4.1. Esta arquitectura de software es consistente con flujos recientes de agricultura de precisión basados en UAV, donde el preprocesamiento geométrico y radiométrico se separa del modelado estadístico y del análisis espacial.

3. Resultados y discusión

Rendimiento por variedad y localidad

El rendimiento de grano varió entre localidades y variedades, teniéndose así una respuesta diferenciada del cultivo frente al ambiente de producción. En Juan Guerra, los valores de REN1 oscilaron entre 6,04 y 7,77 $t\ ha^{-1}$, mientras que REN2 varió entre 5,74 y 7,54 $t\ ha^{-1}$; en San Hilarión, los rangos fueron de 4,90 a 7,40 $t\ ha^{-1}$ para REN1 y de 4,50 a 6,80 $t\ ha^{-1}$ para REN2. A nivel de localidad, Juan Guerra presentó promedios superiores a San Hilarión tanto en REN1 como en REN2, con medias de $7,00 \pm 0,58$ y $6,68 \pm 0,59\ t\ ha^{-1}$, respectivamente, frente a $6,30 \pm 0,69$ y $5,87 \pm 0,66\ t\ ha^{-1}$. Esta diferencia sugiere un entorno más favorable en Juan Guerra para la expresión del potencial productivo del cultivo, con posible ventaja en condiciones de suelo, retención hídrica y uniformidad del dosel. En arroz, la sensibilidad del rendimiento frente a diferencias microambientales y de etapa fenológica ya ha sido documentada en modelos basados en UAV, donde la relación entre señal espectral y productividad depende tanto del sitio como del momento de observación por **Zhou et al. (2017)** y **Luo et al. (2022)**.

La comparación varietal mostró que INIA 509 La Esperanza fue el material de mejor desempeño relativo en ambos ambientes. En Juan Guerra, su REN2 promedio fue $7,04 \pm 0,58\ t\ ha^{-1}$, seguido por INIA 507 La Conquista con $6,77 \pm 0,55\ t\ ha^{-1}$ y INIA 516 LM1 La Unión 23 con $6,23 \pm 0,52\ t\ ha^{-1}$. En San Hilarión, INIA 509 volvió a ocupar el primer lugar con $6,30 \pm 0,44\ t\ ha^{-1}$, mientras que INIA 507 e INIA 516 LM1 registraron $6,10 \pm 0,36$ y $5,20 \pm 0,61\ t\ ha^{-1}$, respectivamente. La persistencia de INIA 509 como la variedad de mayor rendimiento relativo en ambos sitios indica mayor estabilidad agronómica dentro del gradiente edafoclimático evaluado. Este comportamiento es consistente con estudios recientes que muestran que la capacidad predictiva del rendimiento mejora cuando el modelo incorpora diferencias fenotípicas y varietales, debido a que los cultivares no responden de manera homogénea a la señal espectral ni a las condiciones ambientales. **Zhang et al. (2025b)** reportaron que en

arroz japónica híbrido y convencional las correlaciones entre rendimiento y rasgos fenotípicos como cobertura de dosel y área foliar superaron 0,85, y que el mejor modelo alcanzó $R^2 = 0,86$ y $RMSE = 0,59 \text{ t ha}^{-1}$ en etapa de espigamiento, lo que confirma la necesidad de considerar estabilidad varietal en la interpretación del rendimiento derivado de imágenes UAV.

La reducción entre REN1 y REN2 fue moderada y mayor en San Hilarión que en Juan Guerra. En la **Tabla 1**, la diferencia porcentual media entre ambos indicadores fue de 4,62 % en Juan Guerra y de 6,89 % en San Hilarión. Este patrón indica que el ajuste del rendimiento a humedad estándar tuvo mayor efecto en el segundo sitio, lo que podría estar asociado a diferencias en condición del grano, oportunidad de cosecha o microambiente al momento del muestreo. La importancia de esta corrección no es menor, porque la variable de referencia usada para entrenar y validar los mapas espectrales debe ser estandarizada y comparable. En revisiones sobre estimación de rendimiento con UAV, se ha señalado que los errores en definición de la variable objetivo, manejo de humedad de cosecha y heterogeneidad del dato de campo afectan directamente la robustez del modelado y la transferibilidad de los resultados. **Gade et al. (2025)** sintetizaron 100 estudios y concluyeron que la estandarización del flujo de datos y de la medición agronómica es un requisito central para mejorar la confiabilidad de los modelos de rendimiento, mientras que **Aman et al. (2026)** destacaron que la calidad del dato de

campo sigue siendo uno de los cuellos de botella más frecuentes en la validación de modelos de teledetección agrícola.

Distribución del índice SAVI y áreas productivas

Los histogramas del índice SAVI mostraron una separación bastante clara y consistente entre las áreas productivas y las no productivas. En general, las zonas productivas se concentraron sobre todo en valores de 0,50 a 0,70, mientras que las no productivas aparecían con más frecuencia entre 0,30 y 0,50. Esta diferencia se vio tanto al mirar el conjunto completo de variedades como dentro de cada material genético por separado, aunque claro, con variaciones en la amplitud y en la forma de las distribuciones. La nitidez de ese patrón deja ver que el SAVI sí logró captar las diferencias en vigor del dosel y en cobertura vegetal que van ligadas al rendimiento real de la parcela. Y esto encaja perfecto con lo que dice la literatura reciente, que pone al SAVI entre los índices más maduros y confiables en agricultura de precisión cuando hay influencia del suelo de fondo, cobertura vegetal que no cierra del todo o heterogeneidad dentro del lote. **Zhang et al. (2025a)** comentaron que NDVI, GNDVI y SAVI siguen siendo los más consolidados para monitoreo con UAV multispectral, mientras que **Peticilă et al. (2025)**, en su revisión de 472 publicaciones, documentaron que los índices derivados de UAV mantienen una utilidad bien robusta para predecir rendimiento, estrés y biomasa, sobre todo cuando se combinan con aprendizaje automático.

Tabla 1
Rendimiento resumido por localidad y variedad durante la campaña agrícola

Localidad	Variedad	REN1 media ± DE	REN1 mín. a máx.	REN2 media ± DE	REN2 mín. a máx.
Juan Guerra	INIA 507 La Conquista	7,23 ± 0,51	6,70 a 7,71	6,77 ± 0,55	6,16 a 7,21
Juan Guerra	INIA 509 La Esperanza	7,20 ± 0,64	6,51 a 7,77	7,04 ± 0,58	6,40 a 7,54
Juan Guerra	INIA 516 LM1 La Unión 23	6,58 ± 0,55	6,04 a 7,13	6,23 ± 0,52	5,74 a 6,77
San Hilarión	INIA 507 La Conquista	6,43 ± 0,32	6,20 a 6,80	6,10 ± 0,36	5,80 a 6,50
San Hilarión	INIA 509 La Esperanza	6,87 ± 0,46	6,60 a 7,40	6,30 ± 0,44	6,00 a 6,80
San Hilarión	INIA 516 LM1 La Unión 23	5,60 ± 0,61	4,90 a 6,00	5,20 ± 0,61	4,50 a 5,60

Nota. REN1 = rendimiento bruto de campo. REN2 = rendimiento ajustado a humedad estándar.

Tabla 2
Distribución resumida de áreas productivas y no productivas por localidad y variedad

Localidad	Variedad	Área productiva media (%)	DE	Mín. a máx.
Juan Guerra	INIA 507 La Conquista	83,78	7,45	75,95 a 90,20
Juan Guerra	INIA 509 La Esperanza	90,70	2,13	88,24 a 92,10
Juan Guerra	INIA 516 LM1 La Unión 23	89,66	1,08	88,71 a 90,83
San Hilarión	INIA 507 La Conquista	70,58	26,69	51,71 a 89,45
San Hilarión	INIA 509 La Esperanza	74,12	5,13	68,10 a 77,41
San Hilarión	INIA 516 LM1 La Unión 23	75,61	6,43	68,24 a 79,35

Nota. CP = área productiva. SP = área no productiva.

La distribución espacial de áreas clasificadas como productivas también mostró contrastes claros entre localidades. En Juan Guerra, el porcentaje promedio de área productiva fue 88,05%, mientras que en San Hilarión fue 73,80%. A nivel varietal, INIA 509 La Esperanza alcanzó el mayor promedio de área productiva en Juan Guerra, con 90,70%, y el mayor valor individual del estudio, con 92,10% en el bloque III. En San Hilarión, los promedios descendieron a 74,12% para INIA 509, 75,61% para INIA 516 LM1 y 70,58% para INIA 507. Esta diferencia entre sitios sugiere que la señal espectral del dosel y la proporción de áreas de alta productividad estuvieron condicionadas no solo por la genética, sino también por el entorno local de crecimiento. El hallazgo es compatible con estudios recientes en arroz que muestran que la capacidad de los índices UAV para representar rendimiento depende del estadio fenológico, la estructura del dosel y el contexto agroecológico. En Lambayeque, Perú, **Quille et al. (2025)** obtuvieron $R^2 = 0,69$ en etapas de floración y llenado de grano con modelos lineales múltiples, y $R^2 = 0,78$ en etapa de masa, lo que confirma que la asociación entre señal espectral y rendimiento es

real pero sensible al entorno y al momento de observación. Desde el punto de vista operativo, la separación que se ve en el SAVI tiene bastante valor porque convierte esa variabilidad agronómica en patrones espaciales para su interpretación. **Liang et al. (2025)** mostraron que, al integrar 69 índices de vegetación junto con variables meteorológicas, la precisión del modelado subió entre un 10,7% y un 12,9% comparado con los modelos que solo usaban índices. Eso deja claro que la señal espectral aporta información útil, pero se puede potenciar bastante incluyendo variables complementarias. En este estudio, aunque se apoyó principalmente en el SAVI, la consistencia que hay entre el histograma, cómo se distribuyen espacialmente las clases y el rendimiento real medido en campo indica que el índice sí actuó como una variable discriminante efectiva en condiciones de selva baja tropical. Este hallazgo es relevante, porque en ambientes tropicales húmedos una corrección parcial del efecto del suelo puede resultar más práctica que índices que se saturan fácilmente, sobre todo cuando la cobertura vegetal no es del todo homogénea.

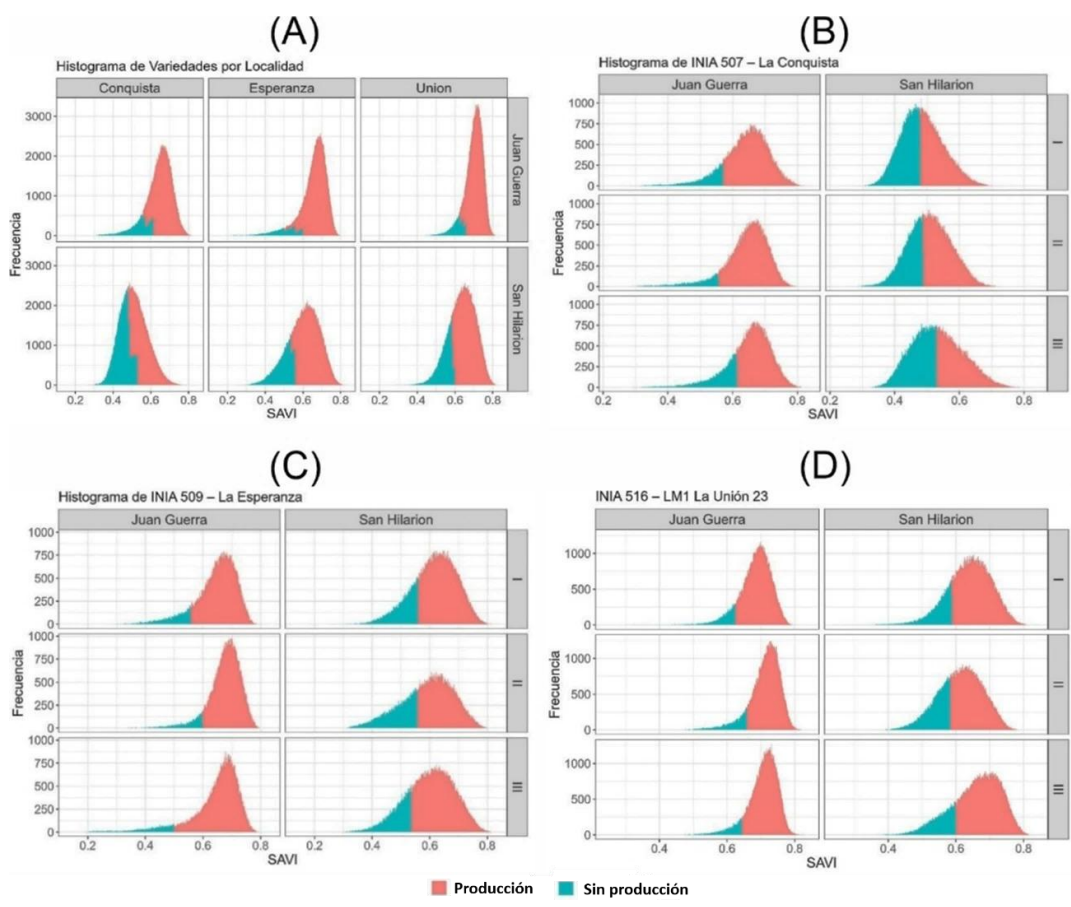


Figura 5. Histogramas del índice SAVI por (A) variedad general, (B) INIA 507 – La Conquista; (C) INIA 509 – La Esperanza; (D) INIA 516 LM1 – La Unión 23.

Desempeño de los modelos de clasificación

Los cinco modelos supervisados que evaluamos dieron resultados bastante altos y parecidos entre sí, Logistic Regression y Support Vector Machine se llevaron las mayores exactitudes, con 88,91% y 88,92% respectivamente, seguidos por KNN con 87,82%, Random Forest con 87,58% y Decision Tree con 87,55% (Tabla 3). Sin embargo, al comparar precisión, recall, specificity y F1 score, Logistic Regression y SVM volvieron a destacar por lograr el mejor equilibrio entre errores de omisión y de comisión. Logistic Regression llegó a una precisión de 91,70%, recall de 94,01%, specificity de 72,32% y F1 score de 92,84%, mientras que SVM quedó muy cerca con 91,62%, 94,12%, 72,00% y 92,85%. En cambio, Decision Tree tuvo el recall más alto, con 94,38%, pero la specificity más baja de todas, apenas 65,35%, lo que muestra que le costaba más controlar los falsos positivos en la clase productiva. La lectura metodológica de este resultado es relevante. Aunque los modelos basados en árboles y ensamblajes suelen mostrar ventajas en problemas no lineales, en este caso la variable dominante fue un índice único con capacidad discriminante relativamente clara, por lo que una frontera lineal o cuasi lineal pudo ser suficiente para separar clases. Esto ayuda a explicar por qué Logistic Regression y SVM rindieron tan bien con menor complejidad estructural. Esta observación es consistente con hallazgos recientes. Haseeb et al. (2025) reportaron que modelos lineales y no lineales pueden comportarse de manera competitiva cuando las variables de entrada muestran relaciones estables con la respuesta, mientras que Jhajharia et al. (2025) señalaron que, en predicción de rendimiento con datos satelitales y aprendizaje automático, SVM fue el método de mejor desempeño entre los algoritmos evaluados. Del mismo modo, Gade et al. (2025) concluyeron que los modelos supervisados continúan siendo los más utilizados y eficaces para cultivos extensivos, y que Random Forest y modelos lineales siguen figurando entre las opciones más confiables para cereales como arroz, trigo y maíz. El buen desempeño de SVM y Logistic Regression también trae implicancias prácticas bien interesantes. En contextos de agricultura tropical donde la infraestructura analítica suele ser limitada, modelos más sencillos y que consumen menos recursos computacionales facilitan mucho más su adopción real para clasificar dentro de la parcela, sobre todo si el objetivo no es armar un sistema multimodal supercomplejo, sino simplemente diferenciar zonas con distinta probabilidad de productividad. La literatura reciente respalda bastante esta idea. Tripathi

et al. (2025) desarrollaron modelos de predicción de rendimiento en arroz usando sensores RGB en UAV y lograron un RMSE de 0,27 t ha⁻¹ con Random Forest, pero al mismo tiempo advirtieron que estos modelos necesitan una validación multitemporal y en varios sitios antes de pensar en escalarlos. De forma complementaria, Saha et al. (2025) destacaron que la agricultura de precisión probablemente se inclinará por esquemas híbridos y escalables, aunque la utilidad real de los modelos depende más de cómo manejan la variabilidad intra campo que de solo buscar la máxima complejidad algorítmica.

Integración agronómica de los hallazgos y alcances del estudio

La integración entre rendimiento medido en campo, distribución de SAVI y clasificación supervisada indica que la metodología fue capaz de capturar heterogeneidad intra parcela con valor agronómico real en condiciones de selva baja tropical (Tabla 4). El estudio no demuestra aún predicción continua de rendimiento con validación multitemporal multi-sitio, ni permite afirmar optimización directa de fertilización, riego o control de estrés. Sin embargo, demuestra que una combinación operativamente simple entre un índice ajustado por suelo y modelos supervisados puede diferenciar espacialmente zonas productivas y no productivas con exactitudes cercanas al 89%, lo que tiene utilidad práctica para monitoreo de parcelas experimentales y priorización de observación agronómica. Esto es especialmente valioso en contextos donde el acceso a sensores, software y procesamiento avanzado es limitado y donde los sistemas de apoyo a la decisión deben comenzar por herramientas parsimoniosas y localmente validadas.

El valor añadido del estudio radica en su validación local. Buena parte de los trabajos recientes se han desarrollado en Asia, Norteamérica o Europa, mientras que en el Perú son escasos los estudios con integración de imágenes UAV, índices espectrales y aprendizaje automático en arroz. Así, el presente trabajo aporta evidencia en la Amazonía peruana con tres variedades locales, dos ambientes contrastantes y resolución espacial de 2,08 cm por píxel, lo que fortalece su pertinencia para agricultura de precisión regional. Además, la consistencia observada en INIA 509 La Esperanza, tanto en rendimiento como en proporción de área productiva, refuerza la coherencia entre medición agronómica y clasificación espacial. Este punto es relevante porque la literatura reciente insiste en que la transferibilidad de los modelos sigue siendo uno de los principales desafíos de la teledetección agrícola.

Tabla 3

Desempeño comparativo de los modelos supervisados evaluados

Modelo	Exactitud (%)	Precisión (%)	Recall (%)	Especificidad (%)	F1 score (%)	AUC	Observación
Logistic Regression	88,91	91,70	94,01	72,32	92,84	NR	Mejor equilibrio entre sensibilidad y especificidad
SVM	88,92	91,62	94,12	72,00	92,85	NR	Desempeño prácticamente equivalente a Logistic Regression
KNN	87,82	91,21	93,04	70,84	92,12	NR	Buen recall, menor especificidad
Random Forest	87,58	90,98	92,97	70,04	91,97	NR	Desempeño estable, sin ventaja clara sobre modelos simples
Decision Tree	87,55	89,86	94,38	65,35	92,06	NR	Mayor recall, pero peor control de falsos positivos

Nota. NR = no reportado, porque no se dispuso de probabilidades ni curva ROC.

Tabla 4

Comparación del presente estudio con literatura relevante sobre arroz y metodologías afines

Estudio	Cultivo	Sensor o plataforma	Índices o variables	Modelo(s)	Tipo de salida	Métricas reportadas	Hallazgo principal
Presente estudio	Arroz	UAV multiespectral MicaSense RedEdge MX y MX Blue	SAVI como variable principal de clasificación	Logistic Regression, SVM, KNN, Random Forest, Decision Tree	Clasificación binaria de zonas productivas y no productivas	Accuracy = 88,91% a 88,92% en Logistic Regression y SVM; F1 = 92,84% a 92,85%; specificity = 72,00% a 72,32%	Logistic Regression y SVM lograron el mejor equilibrio entre sensibilidad y especificidad en selva baja tropical; INIA 509 alcanzó 90,70 % de área productiva media en Juan Guerra
Zhou et al. (2017)	Arroz	UAV multiespectral y digital	Índices multitemporales; bandas red edge y NIR con alta correlación con LAI y rendimiento	Regresión basada en VIs	Rendimiento continuo	La fuente abierta confirma que los VIs multitemporales y las combinaciones red edge 720 nm y NIR 800 nm fueron las más efectivas; NR para R ² en la vista abierta	Identificó el mejor periodo y los VIs óptimos para predicción de rendimiento de arroz; demostró que sensores multiespectrales y digitales en UAV son plataformas confiables para estimar crecimiento y rendimiento
Yang et al. (2019)	Arroz	UAV con imágenes RGB y multiespectrales de muy alta resolución	Imágenes crudas y rasgos espaciales, más que solo VIs	CNN profunda	Rendimiento continuo	La fuente abierta indica mejor desempeño que modelos de regresión basados en VIs; NR para R ² o RMSE en la vista accesible	Las CNN entrenadas con RGB y multiespectral superaron a los modelos basados solo en índices; el desempeño mejoró al incluir más momentos fenológicos en el entrenamiento
Wan et al. (2020)	Arroz	UAV RGB y multiespectral	Información espectral y estructural multitemporal	Model transfer y modelos predictivos	Rendimiento continuo	NR en la vista abierta; se reporta que la fusión multitemporal logró la mejor predicción y que la transferencia entre años mejoró la exactitud	La fusión de imágenes multitemporales produjo la mejor predicción; la etapa inicial de espigamiento fue la óptima; la transferencia entre años mejoró la precisión del modelo

Bellis et al. (2022)	Arroz	UAV multitemporal con enfoque de imágenes a lo largo de la campaña	Imágenes multitemporales y señales espaciales del dosel	3D CNN y estrategias profundas comparadas con aprendizaje estadístico tradicional	Rendimiento espacial continuo	RMSE = 8,8% de la media del rendimiento en el conjunto de prueba	Las estrategias profundas mejoraron a regresión lineal y gradient boosted decision trees para predecir rendimiento espacial en arroz irrigado
Quille et al. (2025)	Arroz	UAV en parcelas comerciales de Lambayeque, Perú	NDVI, SP, DVI, NDRE, GNDVI, EVI2 y texturas GLCM	MLR, SVR, Random Forest	Rendimiento continuo	MLR: R ² = 0,69 en floración y llenado lechoso; R ² = 0,78 en masa en 2022; RF: R ² = 0,58 en análisis combinado 2022 a 2023, con validación cruzada	La integración de índices espectrales y texturales mejoró la predicción de rendimiento; se recomendó incorporar variables climáticas para refinar precisión en ambientes diversos
Liang et al. (2025)	Arroz	UAV multispectral multitemporal más variables meteorológicas en tres zonas agroecológicas de China	69 VIs y 10 variables meteorológicas por etapa; NDRE y TCI/OSAVI entre las más influyentes	SLR, PLSR, RF, GPR, SVM, XGB	Rendimiento continuo	Mejor modelo XGB de cinco periodos: R ² = 0,83; integrar meteorología mejoró la precisión entre 10,7% y 12,9% frente a usar solo VIs	La integración de VIs multitemporales con clima mejoró claramente la predicción de rendimiento; NDRE en espigamiento y TCI/OSAVI en macollamiento fueron variables influyentes
Zhou et al. (2025)	Arroz	UAV multispectral en ensayos de mejoramiento con múltiples variedades	Rasgos basados en características e imágenes multitemporales	RF, DNN, LSTM, 2D CNN y 3D CNN	Rendimiento continuo	Mejor modelo CNN multitemporal 2D: R ² = 0,73; RRMSE = 8,13%	Los modelos profundos basados en imágenes superaron a los modelos basados en características; el mejor periodo fue de floración a llenado de grano
Yu et al. (2025)	Arroz	Insumos de teledetección para ML	DVI, NDVI, RVI y SAVI	Tres modelos ML y DNN	Rendimiento continuo	La vista abierta confirma predicciones precisas con RMSE reportado, pero no muestra el valor exacto; DNN fue el mejor	Los modelos ML generaron predicciones precisas de rendimiento de arroz a partir de DVI, NDVI, RVI y SAVI; el modelo DNN fue superior
Haseeb et al. (2025)	Trigo	Datos de teledetección y clima	Variables remotas y meteorológicas	Modelos lineales y no lineales	Rendimiento continuo	La revisión previa indica comparación competitiva entre enfoques lineales y no lineales; la vista específica no fue abierta aquí	Mostró que la superioridad de modelos complejos no debe asumirse a priori cuando la estructura de los datos favorece relaciones estables
Zhang et al. (2025a)	Multicultivo	Revisión de UAV multispectral en agricultura de precisión	NDVI, GNDVI, SAVI, TCARI, RDVI, OSAVI y algoritmos inteligentes	Revisión	Monitoreo, nutrición, plagas y rendimiento	Revisión cualitativa; sin métrica única de desempeño; destaca madurez de NDVI, GNDVI y SAVI	Concluyó que los índices tradicionales ya tienen aplicación madura y que la mejora actual depende de integración algorítmica, precisión y optimización del flujo de datos
Castilho Silva et al. (2025)	Maíz	UAV multispectral	Índices multispectrales y contenido foliar de N	Modelado agronómico para planificación y optimización	Soporte a decisión relacionado con productividad	No se incorporó aquí una métrica única porque se usa como antecedente metodológico transversal	Mostró que las imágenes UAV e índices espectrales pueden sustentar decisiones agronómicas de sitio específico

Zhang et al. (2025a) que los retos actuales están menos en la disponibilidad de índices y más en la integración algorítmica, la optimización del flujo de procesamiento y la validación en condiciones reales de producción; Aman et al. (2026) enfatizaron la misma necesidad a escala general para estimación de rendimiento basada en sensores remotos.

El alcance del estudio debe interpretarse con prudencia. La evidencia se limita a una campaña agrícola, dos localidades, tres variedades, una salida binaria productiva y no productiva y un modelado dominado por una variable espectral principal. Además, la unidad analítica pixelada podría introducir dependencia espacial entre observaciones vecinas, por lo que futuras investigaciones deberían incorporar más campañas, más sitios, validación temporal, partición espacial explícita y, de ser posible, integración de variables meteorológicas, texturales o estructurales. Liang et al. (2025) mostraron que la incorporación de variables meteorológicas mejoró la precisión de predicción entre 10,7% y 12,9%, mientras que Mena et al. reportaron para predicción subfield multimodal $R^2 = 0,68$ a nivel subparcela y alrededor de 0,80 al nivel de campo en distintos países, lo que evidencia el potencial de enfoques más integrados para fases posteriores de desarrollo metodológico.

4. Conclusiones

Las imágenes multiespectrales obtenidas con UAV y el índice SAVI permitieron discriminar patrones espaciales de productividad en parcelas arroceras de selva baja tropical, mostrando una separación consistente entre zonas productivas y no productivas y coherencia con los rendimientos medidos en campo, donde Juan Guerra registró valores medios superiores a San Hilarión y la variedad INIA 509 La Esperanza presentó el desempeño agronómico más estable entre localidades. Asimismo, los modelos Logistic Regression y Support Vector Machine alcanzaron el mejor equilibrio de clasificación, con exactitudes cercanas a 88,9%, valores de F1 próximos a 92,8% y especificidades alrededor de 72%, lo que indica que una estrategia basada en un índice espectral ajustado por suelo y algoritmos supervisados de complejidad moderada puede ser útil para el monitoreo intra parcela del arroz bajo condiciones tropicales. En términos aplicados, estos resultados respaldan el uso de cartografía espectral como apoyo para identificar heterogeneidad espacial del cultivo y priorizar observación agronómica dentro del lote, sin extender la inferencia a decisiones de manejo no evaluadas directamente.

Debido a que el estudio se realizó en una sola campaña, dos localidades y tres variedades, y se basó principalmente en una salida binaria de productividad, se requiere validación multitemporal y multisitio, así como la incorporación de variables edáficas, meteorológicas y texturales, dado que estudios recientes han mostrado mejoras de 10,7% a 12,9% al integrar clima con índices de vegetación y desempeños de hasta $R^2 = 0,83$ en esquemas multivariados de predicción de rendimiento.

Contribución de los autores

A. Ysuiza-Pérez: Conceptualization; Data curation; Methodology; Investigation; Validation; Visualization; Writing – original draft. **M. Pérez-Tello:** Data curation; Investigation; Validation; Visualization; Writing – review & editing. **D. Goigochea-Pinchi:** Data curation; Formal analysis; Investigation; Visualization; Writing – review & editing. **S. Vega-Herrera:** Investigation; Resources; Project administration; Validation. **R. Ríos-Ríos:** Investigation; Data curation; Validation; Visualization. **P. Domínguez-Yap:** Supervision; Investigation; Validation; Project administration. **L. García:** Data curation; Formal analysis; Visualization; Writing – review & editing. **C. Barrera-Torres:** Validation; Methodology; Investigation; Data curation. **C. Oliva-Cruz:** Conceptualization; Methodology; Supervision; Project administration; Writing – review & editing. **M. Santillán-González:** Supervision; Project administration; Funding acquisition; Resources; Writing – review & editing. **D. Arratea-Pillco:** Data curation; Formal analysis; Visualization; Investigation; Writing – original draft; Writing – review & editing. **I. W. Alejos-Patiño:** Validation; Investigation; Visualization; Writing – review & editing.

ORCID

A. Ysuiza-Perez [ID](https://orcid.org/0009-0006-9126-837x) <https://orcid.org/0009-0006-9126-837x>
 M. Perez-Tello [ID](https://orcid.org/0009-0001-8031-3714) <https://orcid.org/0009-0001-8031-3714>
 D. Goigochea-Pinchi [ID](https://orcid.org/0009-0001-4473-5936) <https://orcid.org/0009-0001-4473-5936>
 S. Vega-Herrera [ID](https://orcid.org/0000-0003-1930-1439) <https://orcid.org/0000-0003-1930-1439>
 R. Rios-Rios [ID](https://orcid.org/0009-0004-3730-6852) <https://orcid.org/0009-0004-3730-6852>
 P. Dominguez-Yap [ID](https://orcid.org/0000-0002-2946-1383) <https://orcid.org/0000-0002-2946-1383>
 L. García [ID](https://orcid.org/0000-0003-2371-8616) <https://orcid.org/0000-0003-2371-8616>
 C. Barrera-Torres [ID](https://orcid.org/0009-0005-6503-1398) <https://orcid.org/0009-0005-6503-1398>
 C. Oliva-Cruz [ID](https://orcid.org/0000-0003-1550-8977) <https://orcid.org/0000-0003-1550-8977>
 M. Santillán-González [ID](https://orcid.org/0009-0001-8791-7262) <https://orcid.org/0009-0001-8791-7262>
 D. Arratea-Pillco [ID](https://orcid.org/0000-0003-0703-2913) <https://orcid.org/0000-0003-0703-2913>
 I. W. Alejos-Patiño [ID](https://orcid.org/0000-0002-2549-5623) <https://orcid.org/0000-0002-2549-5623>

Referencias bibliográficas

- Aman, M., Abdul Sattar, M., Mansoor, J., Ziqi, H., Fuzhong, L., Sanaullah, J., & Syed Aziz, S. (2026). A review of remote sensing-based crop yield estimation: machine learning techniques and environmental, algorithmic, and hardware limitations. *Frontiers*, 17. <https://doi.org/10.3389/fpls.2026.1742689>
- Avtar, R., Suab, S. A., Syukur, M. S., Korom, A., Umarhadi, D. A., & Yunus, A. P. (2020). Assessing the influence of UAV altitude on extracted biophysical parameters of young oil palm. *Remote Sensing*, 12(18), 3030. <https://doi.org/10.3390/RS12183030>
- Barjaktarovic, M., Santoni, M., & Bruzzone, L. (2024). Design and Verification of a Low-Cost Multispectral Camera for Precision Agriculture Application. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 6945-6957. <https://doi.org/10.1109/JSTARS.2024.3377104>
- Bellis, E. S., Hashem, A. A., Causey, J. L., Runkle, B. R. K., Moreno-García, B., Burns, B. W., Green, V. S., Burcham, T. N., Reba, M. L., & Huang, X. (2022). Detecting Intra-Field Variation in Rice

- Yield With Unmanned Aerial Vehicle Imagery and Deep Learning. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.716506>
- Castilho Silva, D., Madari, B. E., Santana Carvalho, M. da C., Costa, J. V. S., & Ferreira, M. E. (2025). Planning and optimization of nitrogen fertilization in corn based on multispectral images and leaf nitrogen content using unmanned aerial vehicle (UAV). *Precision Agriculture*, 26, 30. <https://doi.org/10.1007/s11119-025-10221-9>
- Fukagawa, N. K., & Ziska, L. H. (2019). Rice: importance for global nutrition. *Journal of Nutritional Science and Vitaminology*, 65, S2-S3. <https://doi.org/10.3177/jnsv.65.S2>
- Gade, S. A., Madolli, M. J., García-Caparrós, P., Ullah, H., Cha-um, S., Datta, A., & Himanshu, S. K. (2025). Advancements in UAV remote sensing for agricultural yield estimation: A systematic comprehensive review of platforms, sensors, and data analytics. In *Remote Sensing Applications: Society and Environment*, 37, 101418. <https://doi.org/10.1016/j.rsase.2024.101418>
- Haseeb, M., Tahir, Z., Mahmood, S. A., & Tariq, A. (2025). Winter wheat yield prediction using linear and nonlinear machine learning algorithms based on climatological and remote sensing data. *Information Processing in Agriculture*, 12(4), 431-444 <https://doi.org/10.1016/j.inpa.2025.02.004>
- INIA. (2010). *Arroz INIA 509 "La Esperanza."*
- Jhajharia, K., Sharma, N. V., & Mathur, P. (2025). A Machine Learning Model for Crop Yield Prediction Using Remote Sensing Data. *International Research Journal of Multidisciplinary Scope*, 6(2), 577-590 <https://doi.org/10.47857/irjms.2025.v06i02.03182>
- Liang, Z., Fu, Z., Kiplagat, D., Wang, W., Yang, J., Li, Z., Cao, Q., Tian, Y., Zhu, Y., Cao, W., & Liu, X. (2025). Rice yield prediction base on UAV multispectral imagery using machine learning methods. *Smart Agricultural Technology*, 12, 101549. <https://doi.org/10.1016/j.atech.2025.101549>
- Luo, S., Jiang, X., Jiao, W., Yang, K., Li, Y., & Fang, S. (2022). Remotely Sensed Prediction of Rice Yield at Different Growth Durations Using UAV Multispectral Imagery. *Agriculture*, 12(9), 1447. <https://doi.org/10.3390/agriculture12091447>
- Mena, F., Pathak, D., Najjar, H., Sanchez, C., Helber, P., Bischke, B., Habelitz, P., Miranda, M., Siddamsetty, J., Nuske, M., Charfuelan, M., Arenas, D., Vollmer, M., & Dengel, A. (2025). Adaptive fusion of multi-modal remote sensing data for optimal sub-field crop yield prediction. *Remote Sensing of Environment*, 318, 114547. <https://doi.org/10.1016/j.rse.2024.114547>
- Miftahshudur, T., Sahin, H. M., Grieve, B., & Yin, H. (2025). A Survey of Methods for Addressing Imbalance Data Problems in Agriculture Applications. *Remote Sensing*, 17(3), 454. <https://doi.org/10.3390/rs17030454>
- MINAGRI. (2025). Observatorio de Commodities: Arroz. *Ministerio de Agricultura y Riego*.
- Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. *Remote Sensing*, 13(19), 3841. <https://doi.org/10.3390/rs13193841>
- Peticilă, A., Iliescu, P. G., Dinca, L., Popa, A. S., & Murariu, G. (2025). Vegetation indices from UAV imagery: Emerging tools for precision agriculture and forest management. *AgriEngineering*, 7(12), 43. <https://doi.org/10.3390/agriengineering7120431>
- Quille, J., Ramos, L., Huanqueño, J., Quispe, D., Cruz, L., Pino, E., Flores, L., Heros, E., & Ángel, L. (2025). Rice Yield Prediction Using Spectral and Textural Indices Derived from UAV Imagery and Machine Learning Models in Lambayeque, Peru. *Remote Sensing*, 17(4), 632. <https://doi.org/10.3390/rs17040632>
- Saha, S., Kucher, O. D., Utkina, A. O., & Rebouh, N. Y. (2025). Precision agriculture for improving crop yield predictions: a literature review. *Frontiers in Agronomy*, 7, 1566201. <https://doi.org/10.3389/fagro.2025.1566201>
- Senamhi. (2025). *Datos Meteorológicos en San Martín*. Descarga de Datos Meteorológicos. <https://www.senamhi.gob.pe/site/descarga-datos/>
- Tripathi, R., Gouda, A. K., Jena, S. S., Mohapatra, R. R., Lal, M. K., Dash, S. K., Sahoo, R. N., & Nayak, A. K. (2025). Rice yield prediction using UAV-mounted RGB sensors and machine learning algorithms. *Proceedings of the Indian National Science Academy*. <https://doi.org/10.1007/s43538-025-00479-y>
- Wan, L., Cen, H., Zhu, J., Zhang, J., Zhu, Y., Sun, D., Du, X., Zhai, L., Weng, H., Li, Y., Li, X., Bao, Y., Shou, J., & He, Y. (2020). Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer – a case study of small farmlands in the South of China. *Agricultural and Forest Meteorology*, 291, 108096. <https://doi.org/10.1016/j.agrformet.2020.108096>
- Yang, Q., Shi, L., Han, J., Zha, Y., & Zhu, P. (2019). Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. *Field Crops Research*, 235, 142-153. <https://doi.org/10.1016/j.fcr.2019.02.022>
- Yu, J., Dong, L., Zeng, W., & Lei, G. (2025). Rice yield predictions from remote sensing inputs in machine learning models. *Agronomy Journal*, 117(6), e70254. <https://doi.org/10.1002/agj2.70254>
- Zhang, L., Liang, X., Li, X., Zeng, K., Chen, Q., & Zhao, Z. (2025). Machine learning models for yield estimation of hybrid and conventional japonica rice cultivars using UAV imagery. *Sustainability*, 17(18), 8515. <https://doi.org/10.3390/su17188515>
- Zhang, S., Wang, X., Lin, H., Dong, Y., & Qiang, Z. (2025). A review of the application of UAV multispectral remote sensing technology in precision agriculture. *Smart Agricultural Technology*, 12, 101406. <https://doi.org/10.1016/j.atech.2025.101406>
- Zhou, H., Huang, F., Lou, W., Gu, Q., Ye, Z., Hu, H., & Zhang, X. (2025). Yield prediction through UAV-based multispectral imaging and deep learning in rice breeding trials. *Agricultural Systems*, 223, 104214. <https://doi.org/10.1016/j.agsy.2024.104214>
- Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., Cheng, T., Zhu, Y., Cao, W. X., & Tian, Y. C. (2017). Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>