



RESEARCH ARTICLE



Spatial modeling of soil physicochemical properties and fertility in tropical agricultural systems under different structural heterogeneity using multispectral UAV and geostatistics

Modelado espacial de propiedades fisicoquímicas y fertilidad del suelo en sistemas agrícolas tropicales bajo distinta heterogeneidad estructural mediante UAV multiespectral y geoestadística

Sergio Vega-Herrera¹ ; Alfredo Ysuiza-Perez¹ ; Mónica Perez-Tello¹ ; Diego Goigochea-Pinchi¹ ; Raúl Rios-Rios¹ ; Percy Dominguez-Yap¹ ; Leonela García¹ ; Cicerón Barrera-Torres¹ ; Carlos Oliva-Cruz^{1*} ; Manuel Santillán-González¹ ; David Arratea-Pillco² ; Italo 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 San Agustín de Arequipa (UNSA), Arequipa, Perú

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

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

Received: 2 November 2025. Accepted: 13 April 2026. Published: 27 April 2026.

Abstract

Spatial variability of soil properties is a key factor that influences productivity, nutrient management, and overall sustainability in tropical agricultural systems. This is especially true where differences in soil types make it difficult to apply site-specific management strategies. In this context, the study sets out to compare the performance of the same analytical workflow based on multispectral UAV imagery, multiple linear regression, and geostatistical interpolation, across two tropical farming systems that differ in their level of structural heterogeneity. One was a station-wide multicrop system, and the other was a rice system under varying planting densities, both located at the El Porvenir Agricultural Experimental Station in San Martín, Peru. The study included 60 soil samples from the multicrop component and 27 from the rice system. All samples were georeferenced and taken at 30 cm depth, then analyzed in the lab for pH, electrical conductivity, nitrogen, phosphorus, potassium, soil organic carbon, and texture. The exact same workflow was applied to both systems: Spearman correlation, stepwise multiple linear regression, and ordinary kriging. Results showed that the rice system gave better predictive accuracy for specific variables like nitrogen and phosphorus. On the other hand, the multicrop component proved more useful for mapping spatial patterns and defining management zones, thanks to its greater heterogeneity. In addition, indices based on NIR and red edge bands had stronger links with the main soil properties. Overall, the performance of the approach clearly depended on the structural heterogeneity of each system: more uniform environments favored point-based predictions, while more variable ones were better suited for operational zoning.

Keywords: precision agriculture; spatial interpolation; vegetation indices; UAV remote sensing; geostatistics; multispectral sensors.

Resumen

La variabilidad espacial del suelo condiciona la eficiencia productiva, la gestión de nutrientes y la sostenibilidad de los sistemas agrícolas tropicales, especialmente en contextos donde la heterogeneidad limita la implementación de estrategias de manejo sitio-específico. En este estudio se comparó el desempeño de un flujo analítico basado en imágenes UAV multiespectrales, regresión lineal múltiple (MLR) e interpolación geoestadística en dos sistemas agrícolas con distinta heterogeneidad, un sistema multicrop a escala de estación y un sistema arrocero con diferentes densidades de siembra, ambos ubicados en la Estación Experimental Agraria El Porvenir (San Martín, Perú). Se analizaron 60 muestras en el componente multicrop y 27 en el sistema arrocero, georeferenciadas a 30 cm de profundidad, evaluando pH, conductividad eléctrica, nitrógeno, fósforo, potasio, carbono orgánico del suelo y textura. Se aplicó un flujo analítico homogéneo en ambos sistemas (correlación de Spearman, MLR stepwise y kriging ordinario). Los resultados evidenciaron diferencias marcadas en el desempeño predictivo, en el sistema arrocero se alcanzaron valores de R^2 de prueba de 0,93 para nitrógeno y 0,88 para fósforo, mientras que en el sistema multicrop los mayores R^2 fueron 0,42 para conductividad eléctrica y 0,37 para limo. Asimismo, los índices espectrales basados en NIR y red edge mostraron mayor asociación con los atributos edáficos evaluados. Los resultados demuestran que el desempeño depende de la heterogeneidad estructural del sistema, donde entornos más homogéneos favorecen la predicción puntual, mientras que sistemas más heterogéneos potencian la zonificación y delimitación de unidades de manejo.

Palabras clave: agricultura de precisión; interpolación espacial; índices de vegetación; teledetección con UAV; geoestadística; sensores multiespectrales.

DOI: <https://doi.org/10.17268/sci.agropecu.2026.035>

Cite this article:

Vega-Herrera, S., Ysuiza-Perez, A., Perez-Tello, M., Goigochea-Pinchi, D., Rios-Rios, R., Dominguez-Yap, P., García, L., Barrera-Torres, C., Oliva-Cruz, C., Santillán-González, M., Arratea-Pillco, D., & Alejos-Patiño, I. (2026). Modelado espacial de propiedades fisicoquímicas y fertilidad del suelo en sistemas agrícolas tropicales bajo distinta heterogeneidad estructural mediante UAV multiespectral y geoestadística. *Scientia Agropecuaria*, 17(2), 497-512.

1. Introducción

La variabilidad espacial del suelo constituye un problema agronómico de primer orden porque condiciona simultáneamente la disponibilidad de nutrientes, la salinidad, la acidez, la retención de agua y la eficiencia de respuesta del cultivo a la fertilización y al manejo hídrico, especialmente en sistemas agrícolas tropicales donde la heterogeneidad edáfica se amplifica por procesos de meteorización, lixiviación y diversidad de coberturas; en este contexto, la evidencia reciente sobre manejo nutricional en sitios específicos han demostrado que la heterogeneidad intrapredial no puede seguir abordándose mediante esquemas uniformes de muestreo y recomendación, ya que la delimitación espacial de unidades de manejo permite mejorar la productividad, reducir pérdidas de insumos y disminuir riesgos de contaminación difusa cuando el diagnóstico se apoya en información espacial de alta resolución, aunque su adopción sigue limitada por vacíos en sensado, integración de datos y selección de modelos robustos, como sintetizan Vullaganti, Ram y Sun en once años de investigación entre 2013 y 2024 (Vullaganti et al., 2025); esta problemática adquiere mayor relevancia en ambientes tropicales húmedos como la Amazonía peruana, donde la variabilidad espacial de atributos como pH, conductividad eléctrica, carbono orgánico y macronutrientes es particularmente alta y condiciona la eficiencia de los sistemas productivos, siendo el arroz un cultivo estratégico dentro del sistema agroalimentario nacional, con seguimiento continuo por el Observatorio de Commodities Arroz N.º 01 2025 del MIDAGRI (MIDAGRI, 2025) y estimaciones del USDA para la campaña 2025 – 2026 de 2,6 millones de toneladas de producción, 2,7 millones de consumo y 100 000 toneladas de importación (USDA, 2025), lo que confirma su peso económico y alimentario; en consecuencia, la necesidad de herramientas de diagnóstico espacial más precisas no responde únicamente a una innovación tecnológica, sino a una exigencia productiva y ambiental, donde el valor agronómico del análisis depende de su capacidad para capturar gradientes espaciales que los promedios de lote no representan adecuadamente.

Los vehículos aéreos no tripulados con sensores multiespectrales han consolidado una base metodológica robusta en agricultura de precisión debido a su capacidad para generar información de alta resolución espacial, flexibilidad temporal y menor costo operativo respecto a muestreos intensivos de campo, lo que ha permitido su aplicación en monitoreo de crecimiento, detección de estrés, evaluación nutricional y predicción de rendimiento;

Zhang et al. (2025b) identificaron estos cuatro dominios principales y señalaron que índices como NDVI, GNDVI y SAVI presentan aplicaciones maduras, mientras que la integración de índices emergentes y enfoques analíticos más avanzados mejora la precisión, en tanto que Gade et al. (2025), al revisar 100 estudios, confirmaron la predominancia de NDVI y el valor de integrar variables espectrales, texturales, térmicas y meteorológicas para mejorar el desempeño; de manera complementaria, Peticilă et al. (2025) analizaron 472 publicaciones entre 2015 y 2024 y evidenciaron el uso recurrente de NDVI, NDRE y GNDVI, así como limitaciones persistentes asociadas a iluminación, fondo de suelo y heterogeneidad de la escena. En arroz, Liang et al. (2025) integraron 69 índices y 10 variables meteorológicas en tres zonas agroecológicas de China y reportaron R^2 de 0,83; Quille et al. (2025), en Lambayeque, Perú, obtuvieron R^2 de 0,69 a 0,78 con regresión lineal múltiple; Zhang et al. (2025) alcanzaron R^2 de 0,86 con random forest en arroz japónica; y Tripathi et al. (2025) lograron RMSE de 0,27 t/ha usando UAV RGB; sin embargo, la literatura converge en que el desempeño depende críticamente del sensor, del preprocesamiento, de la escala de observación y de la integración de variables auxiliares, como señalan Saha et al. (2025), y como refuerzan Caroppo et al. (2026) al evidenciar limitaciones en la estandarización de datasets UAV, lo que indica que, aunque el enfoque UAV multiespectral con índices, regresión y geoestadística cuenta con soporte científico sólido, su desempeño no es directamente transferible entre contextos productivos, sensores y escalas.

A pesar de los avances metodológicos, persiste una brecha en la comparación del desempeño de un mismo flujo analítico basado en UAV multiespectral en sistemas agrícolas tropicales con distinta heterogeneidad estructural, particularmente en la distinción entre capacidad predictiva puntual y utilidad cartográfica, ya que la mayor parte de la literatura se ha concentrado en monocultivos, en estimación de rendimiento más que en propiedades físico-químicas del suelo, o en contextos templados y semi-áridos; en arroz, por ejemplo, estudios como los de Liang et al. (2025), Zhang et al. (2025b) y Quille et al. (2025) han demostrado altos niveles de precisión en condiciones controladas, pero no evalúan dentro de un mismo diseño analítico cómo cambia el desempeño cuando se transita de un sistema homogéneo a uno heterogéneo ni abordan el problema de transferibilidad entre escalas. En ambientes tropicales húmedos, además, la

predicción espectral del suelo enfrenta restricciones adicionales asociadas a cobertura vegetal, humedad y complejidad estructural; **Chen et al. (2024)** mostraron que incluso con UAV hiperespectral y LiDAR la predicción sigue siendo desafiante en bosque tropical, mientras **Novais et al. (2025)** evidenciaron los costos logísticos del muestreo convencional en la Amazonía, y **Suleymanov et al. (2025)** señalaron que la aplicabilidad de UAV para propiedades edáficas aún no está plenamente resuelta en contextos homogéneos de cobertura; más recientemente, **Žydelis et al. (2026)** demostraron que la precisión depende de la fuente de datos, y **Ma et al. (2026)** evidenciaron que la integración de variables UAV, meteorológicas y de manejo mejora la capacidad diagnóstica. La literatura confirma la viabilidad técnica del enfoque, pero aún no resuelve cómo un mismo flujo analítico responde a diferentes niveles de heterogeneidad espacial y agronómica en sistemas tropicales, lo que limita su interpretación operativa y su aplicación comparativa en agricultura de precisión.

Sobre esta base, el objetivo del estudio fue comparar el desempeño de un mismo flujo analítico basado en imágenes UAV multispectrales, regresión lineal múltiple con selección stepwise e interpolación geoestadística para la estimación y zonificación de propiedades físico-químicas y de fertilidad del suelo en un sistema multicultivo y un sistema arrocero tropical de la Amazonía peruana, operacionalizando este propósito en la caracterización de la variabilidad espacial del suelo, la identificación de índices espectrales asociados a atributos edáficos, la evaluación del desempeño del flujo analítico en ambos componentes y la delimitación de patrones espaciales útiles para manejo diferenciado; la pregunta científica subyacente fue si un mismo flujo analítico mantiene desempeño equivalente cuando se aplica en sistemas con distinta heterogeneidad estructural, y la hipótesis principal plantea que el sistema arrocero presentará mayor capacidad predictiva puntual debido a su menor heterogeneidad espacial relativa y manejo agronómico más homogéneo, mientras que la hipótesis complementaria establece que el componente multicultivo presentará menor precisión numérica pero mayor utilidad cartográfica para delimitar unidades de manejo, y adicionalmente se plantea que los índices basados en NIR y Red Edge presentarán mayor asociación con atributos edáficos; esta formulación es consistente con la evidencia reciente que muestra que los mayores niveles de ajuste se logran en sistemas

homogéneos o controlados, mientras que la integración de variables multimodales mejora la precisión, aunque sigue condicionada por el contexto edafoclimático, el sensor y la escala.

2. Metodología

2.1. Área de estudio

El estudio se desarrolló en la Estación Experimental Agraria El Porvenir del Instituto Nacional de Innovación Agraria, ubicada en el distrito de Juan Guerra, provincia y departamento de San Martín, Perú, en la carretera Tarapoto–Juanjuí km 14,5, dentro del corredor agrícola de la selva nororiental peruana, con coordenadas operativas de 6°35'31,81" S y 76°19'15,56" O; la estación constituye un entorno idóneo debido a la articulación entre infraestructura agronómica, capacidad analítica y diversidad productiva, condiciones que permiten evaluar el desempeño de un mismo flujo analítico en escenarios con distinta heterogeneidad estructural y diferente organización del manejo agrícola (**Flores et al., 2025**). El clima corresponde a condiciones tropicales húmedas de la Amazonía peruana, con temperatura media anual cercana a 27 °C, rangos entre 19 °C y 35 °C y una precipitación media anual aproximada de 1 123 mm, lo que asegura disponibilidad hídrica sostenida para cultivos anuales y perennes, condiciones que, junto con la elevada humedad relativa y la nubosidad frecuente, influyen directamente sobre la respuesta espectral del suelo y del dosel, incrementando la necesidad de control en la adquisición de imágenes, la calibración radiométrica y la interpretación de la señal espectral bajo condiciones tropicales (**Flores et al., 2025**). Dentro de este marco se definieron dos componentes de estudio con misma lógica analítica y comparabilidad directa, pero con distinta heterogeneidad estructural, un sistema multicultivo de 60 ha que incluyó arroz, maíz, pastos y forrajes, sacha inchi, algodón, achiote, piñón y plátano, caracterizado por alta variabilidad espacial en cobertura, manejo y condición edáfica (**Figura 1a**), y una subunidad experimental arrocera conformada por tres parcelas de 2 mil m² con densidades de siembra de 0, 20 y 40 kg/ha, representando un entorno agronómicamente más homogéneo (**Figura 1b**); ambos componentes fueron evaluados bajo un mismo flujo metodológico, lo que permitió una comparación directa del desempeño predictivo y cartográfico entre sistemas contrastantes, manteniendo una misma lógica analítica y aislando como eje de comparación principal la heterogeneidad estructural del sistema productivo y la escala de análisis, y no la aplicación de enfoques analíticos distintos.

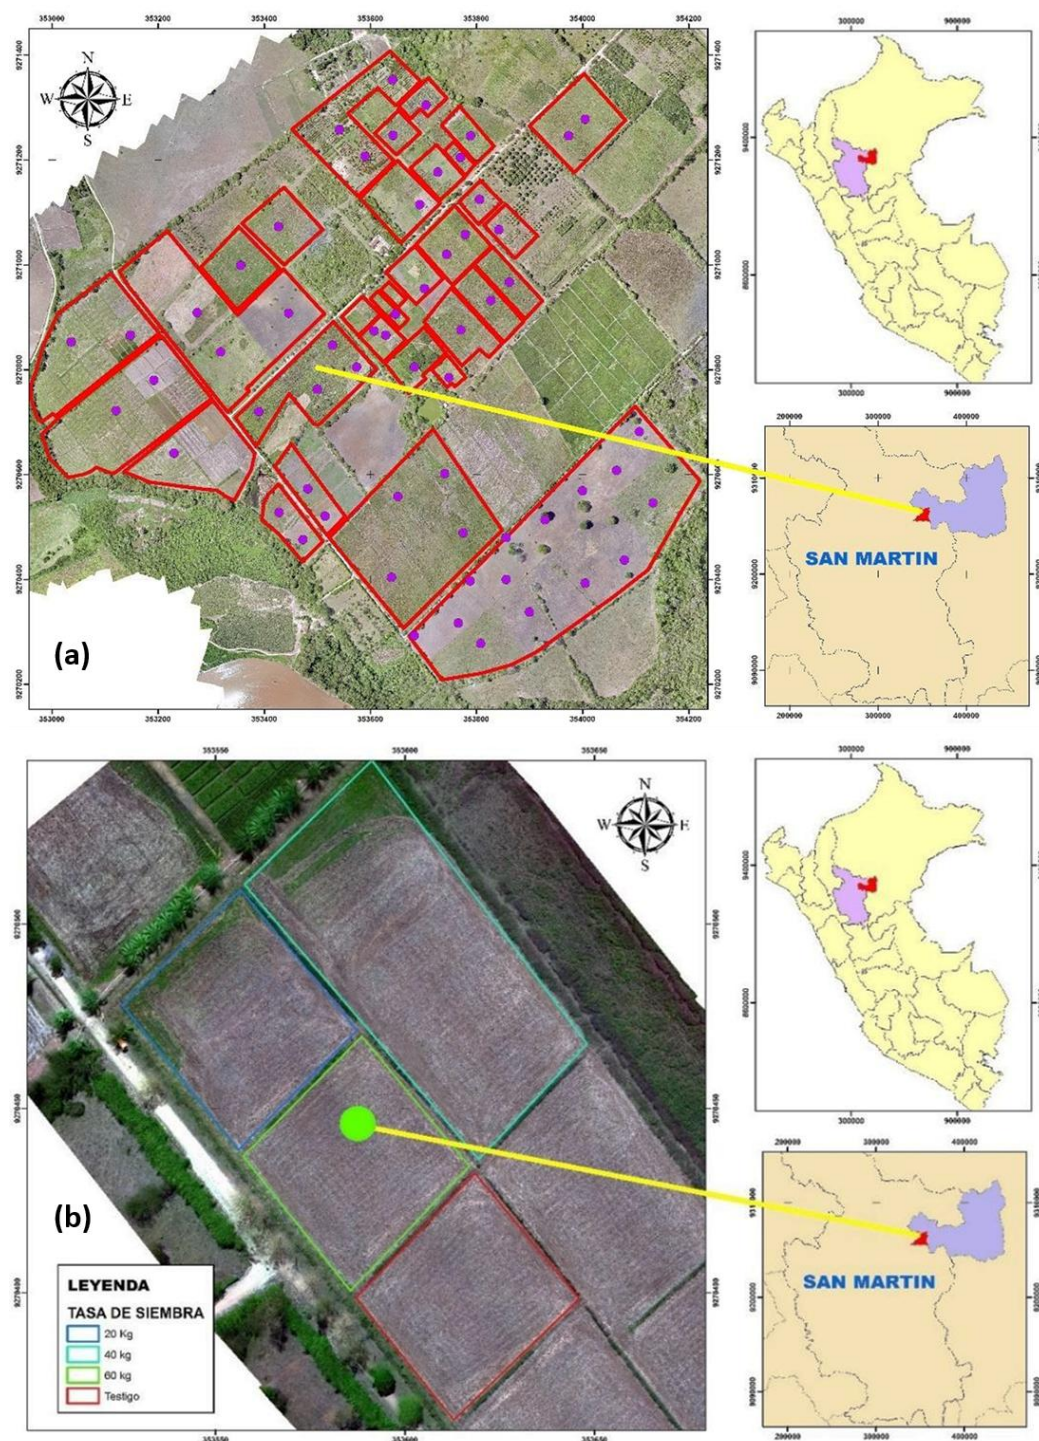


Figura 1. Mapa de distribución de las parcelas en sistemas (a) multicropo a escala de estación y (b) arrozero con diferentes densidades de siembra.

2.2. Diseño del estudio

La investigación adoptó un diseño comparativo con dos niveles analíticos complementarios (Tabla 1), ambos evaluados bajo un mismo flujo analítico con el propósito de determinar cómo varía el desempeño del modelado cuando se aplica en sistemas con distinta heterogeneidad estructural, el

componente 1 correspondió a un diagnóstico espacial station-wide en un sistema multicropo heterogéneo, orientado a representar la variabilidad de propiedades físico-químicas y de fertilidad del suelo a escala de estación, mientras que el componente 2 correspondió a un análisis focal en arroz bajo tres densidades de siembra, orientado a evaluar si una

mayor homogeneidad de manejo y cobertura favorecía la asociación entre variables espectrales derivadas de UAV y atributos edáficos, siendo en ambos casos la unidad de análisis el punto de muestreo georreferenciado vinculado simultáneamente a resultados de laboratorio y a variables espectrales extraídas del ortomosaico, lo que aseguró la aplicación de una misma lógica analítica a escalas distintas; el componente multicultivo tuvo naturaleza observacional y diagnóstica, capturando la variabilidad espacial en una superficie agrícola diversa donde la coexistencia de usos incrementa la complejidad de la relación suelo-sensor, mientras que el componente arrocero tuvo carácter comparativo focal, incorporando un gradiente de densidad de siembra bajo condiciones más homogéneas, constituyendo ambos un diseño jerárquico y no estudios independientes, en el que la hipótesis operativa plantea que el sistema arrocero favorecería la predicción y el sistema multicultivo la zonificación operativa; el tamaño muestral respondió a la disponibilidad operativa, accesibilidad y escala de variación espacial, priorizando cobertura amplia en el multicultivo y mayor control en el arroz, reconociéndose que, aunque suficiente para un análisis exploratorio-comparativo y de zonificación.

2.3. Muestreo y análisis de suelo

El componente multicultivo incluyó 60 muestras de suelo georreferenciadas distribuidas espacialmente para representar la variabilidad interna de 60 ha agrícolas, mientras que el componente arrocero incluyó 27 puntos georreferenciados con nueve puntos por parcela en tres parcelas asociadas a densidades de siembra de 0, 20 y 40 kg/ha, manteniendo en ambos casos una profundidad uniforme de extracción de 30 cm correspondiente al horizonte superficial de mayor actividad agronómica, lo que permitió asegurar comparabilidad directa entre componentes y evitar variabilidad vertical adicional en el análisis, con georreferenciación realizada mediante equipo Garmin GPSMAP 66s para garantizar

la vinculación espacial entre el punto de suelo, el píxel espectral y su posición en los modelos cartográficos; las muestras fueron secadas a temperatura ambiente, desagregadas, homogeneizadas y tamizadas a 2 mm, asegurando estandarización del procesamiento y reduciendo variabilidad preanalítica, mientras que el análisis se realizó en el Laboratorio de Suelos, Aguas y Foliar de la EEA El Porvenir, evitando sesgos interlaboratorio y reforzando la trazabilidad analítica del estudio. Las variables evaluadas incluyeron arena, limo, arcilla, conductividad eléctrica, pH, nitrógeno total, fósforo disponible, potasio intercambiable y carbono orgánico del suelo, cubriendo dimensiones físico-estructurales y químico-funcionales relevantes para fertilidad, comportamiento espectral y calidad del suelo, selección coherente con estudios recientes en San Martín y literatura internacional que evidencia diferencias en la capacidad predictiva según propiedad y fuente de datos (Solórzano et al., 2025; Žydelis et al., 2026); la determinación de pH se realizó según US EPA 9045D (EPA, 2004), la conductividad eléctrica según ISO 11265 (1994), la textura conforme a NOM-021-RECNAT-2000 (SEMARNAT, 2002), el carbono orgánico mediante Walkley-Black, y fósforo y potasio mediante técnicas estandarizadas, consolidando una matriz analítica robusta cuya trazabilidad metodológica se resume en la **Tabla 2**, la cual integra variables, unidades, métodos, normas, laboratorio y justificación agronómica, evitando redundancias y fortaleciendo la replicabilidad del estudio.

2.4. Adquisición y procesamiento de imágenes UAV

La adquisición de imágenes se realizó en dos campañas instrumentales diferenciadas correspondientes a cada componente del estudio, manteniendo en ambos casos bandas espectrales funcionalmente comparables en el visible, NIR y red edge, lo que permitió preservar la misma lógica analítica y la comparabilidad directa entre sistemas pese a su distinta heterogeneidad estructural.

Tabla 1

Diseño comparativo de los componentes del estudio

Componente	Multicultivo	Monocultivo (Arroz)
Escala de análisis	Estación completa	Parcelas experimentales
Superficie (ha)	60	0,6
Sistema/cultivo	Sistema heterogéneo	<i>Oryza sativa</i> (0, 20, 40 kg/ha)
Número de muestras (n)	60	27
Profundidad (cm)	30	30
Momento(s) de muestreo	Un momento (condición base)	Dos momentos (pre y post)
Sensor UAV	DJI Mavic 3 Multispectral	DJI Matrice 300 RTK + RedEdge-P
Bandas disponibles	Green, Red, Red Edge, NIR	Blue, Green, Red, Red Edge, NIR
Resolución espacial (cm/píxel)	4,61	2,08
Variables de suelo	pH, CE, N, P, K, textura, SOC	pH, CE, N, P, K, textura, SOC
Objetivo analítico	Zonificación y variabilidad espacial	Evaluación comparativa de predicción

Tabla 2

Variables de suelo y métodos analíticos

Variable	Unidad	Método analítico	Norma o referencia	Justificación
Arena	%	Método de Bouyoucos (hidrómetro)	Gee & Or (2002)	Determina textura y capacidad de drenaje
Limo	%	Método de Bouyoucos (hidrómetro)	Gee & Or (2002)	Influye en retención de agua y nutrientes
Arcilla	%	Método de Bouyoucos (hidrómetro)	Gee & Or (2002)	Determina capacidad de intercambio catiónico
pH	unidad	Potenciómetro en suspensión suelo-agua (1:2,5)	Sparks (1996)	Regula disponibilidad de nutrientes
CE (conductividad eléctrica)	dS/m	Conductímetro en extracto de saturación	Rhoades (2018)	Indica salinidad y limitaciones productivas
N total	%	Método Kjeldahl	Mulvaney (1996)	Nutriente esencial para crecimiento vegetal
P disponible	mg/kg	Método Olsen (colorimetría)	Olsen et al. (1954)	Nutriente limitante en suelos tropicales
K intercambiable	cmol(+)/kg	Extracción con acetato de amonio	Sparks (1996)	Regula metabolismo y productividad
SOC (carbono orgánico del suelo)	%	Método Walkley-Black modificado	Nelson & Sommers (2018)	Indicador de calidad del suelo y fertilidad

En el componente multicultivo se utilizó un DJI Mavic 3 Multispectral con cuatro bandas espectrales (verde 560 ± 16 nm, rojo 650 ± 16 nm, red edge 730 ± 16 nm y NIR 860 ± 26 nm), ejecutando el vuelo a 100 m de altura, velocidad de 8,9 m/s, con traslape frontal de 80%, lateral de 70% y GSD de 4,61 cm/píxel, cubriendo 412 ha en 3 h 48 min con 6 081 imágenes georreferenciadas bajo condiciones atmosféricas estables; el procesamiento inicial se realizó en Pix4D Fields con corrección radiométrica y geométrica, y la extracción de valores espectrales en ArcGIS 10.8.1 y R. En el componente arrocero se utilizó un DJI Matrice 300 RTK equipado con cámara MicaSense RedEdge-P (azul 475 nm, verde 560 nm, rojo 668 nm, red edge 717 nm y NIR 842 nm), con vuelos antes de la siembra y después de la cosecha sobre suelo limpio, a 50 m de altura, velocidad de 4,5 m/s, solapamiento de 80% y GSD de 2,08 cm/píxel, procesando la información en Pix4Dmapper v4.5.6. Esta diferencia instrumental fue considerada como una posible fuente de variabilidad en la interpretación de resultados, pero no constituyó el eje comparativo del estudio, dado que el objetivo fue evaluar el desempeño de un mismo flujo analítico en sistemas con distinta heterogeneidad estructural y no comparar sensores.

2.5. Índices espectrales

El análisis espectral se estructuró bajo un enfoque de selección controlada, restringiendo el conjunto de variables a índices consistentes y comparables entre ambos componentes, con el fin de evitar la dispersión metodológica y asegurar coherencia con el esquema de regresión lineal múltiple aplicado de manera unificada; en este sentido, se seleccionaron NDVI, GNDVI, NDRE, CIGreen, SAVI, OSAVI, EVI2,

LCI y ReCI o ReCl cuando su formulación fue equivalente entre sensores, mientras que NDWI se mantuvo únicamente cuando mostró participación en correlaciones o modelos finales. Esta depuración permitió reducir redundancias, eliminar índices sin aporte explicativo y garantizar que los predictores utilizados respondieran a criterios de interpretabilidad agronómica y capacidad explicativa dentro del mismo flujo analítico, priorizando índices basados en NIR y Red Edge por su sensibilidad a clorofila, biomasa y propiedades edáficas indirectas. La **Tabla 3** presenta las fórmulas, bandas requeridas y propósito teórico de cada índice, mientras que la **Tabla 4** resume las abreviaturas utilizadas, asegurando consistencia terminológica en el desarrollo del análisis y evitando ambigüedades en la interpretación de resultados.

2.6. Modelamiento estadístico

El enfoque analítico se formuló como *multiple linear regression with variable selection and geostatistical interpolation*. En el componente multicultivo se aplicó regresión lineal múltiple con selección *stepwise* bidireccional, usando como variables dependientes las propiedades del suelo y como predictores bandas espectrales e índices derivados del UAV. La partición fue *train test split* de 70/30 (**Tabla 5**).

2.7. Interpolación espacial

El análisis estadístico se estructuró bajo un enfoque unificado para ambos componentes, empleando regresión lineal múltiple (MLR) con selección de variables tipo *stepwise* como método central de modelado, complementado con análisis de correlación y soporte geoestadístico, la elección de MLR res-

pondió a su interpretabilidad agronómica, trazabilidad estadística y capacidad para identificar relaciones entre variables espectrales y atributos del suelo. En el componente multicultivo se aplicó MLR utilizando como variables dependientes las propiedades edáficas y como predictores bandas e índices espectrales seleccionados, con un esquema de validación holdout 70/30, evaluando el desempeño

mediante R², RMSE y MAE; este mismo esquema se mantuvo en el componente arrocero para asegurar comparabilidad directa. El tamaño muestral respondió a la disponibilidad operativa y a la escala de variación espacial de cada componente, priorizando cobertura espacial en multicultivo y control agronómico en arroz (Tabla 6).

Tabla 3
Índices espectrales utilizados en el estudio

Índice	Fórmula	Bandas requeridas	Multicultivo	Arroz	Propósito teórico
NDVI	$NDVI = \frac{NIR - Red}{NIR + Red}$	NIR, Red	Sí	Sí	Biomasa, vigor vegetal, contraste suelo vegetación
GNDVI	$GNDVI = \frac{NIR - Green}{NIR + Green}$	NIR, Green	Sí	Sí	Estado de clorofila y contenido de nitrógeno
NDRE	$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}$	NIR, Red Edge	Sí	Sí	Sensibilidad a contenido de clorofila en estadios avanzados
SAVI	$SAVI = \left(\frac{NIR - Red}{NIR + Red + L} \right) (1 + L),$ $L = 0,5$	NIR, Red	Sí	Sí	Corrección del efecto del suelo en cobertura baja
OSAVI	$OSAVI = \frac{NIR - Red}{NIR + Red + 0,16}$	NIR, Red	Sí	Sí	Mejora de SAVI en suelos con alta reflectancia
EVI2	$EVI2 = \frac{2,5(NIR - Red)}{NIR + 2,4 \cdot Red + 1}$	NIR, Red	Sí	Sí	Mejora en saturación de NDVI en alta biomasa
Cgreen	$Cgreen = \frac{NIR}{Green} - 1$	NIR, Green	Sí	Sí	Estimación de clorofila foliar
LCI	$LCI = \frac{NIR - RedEdge}{NIR + Red}$	NIR, Red Edge, Red	Sí	Sí	Índice de clorofila y vigor vegetativo
NDWI*	$NDWI = \frac{NIR - Green}{NIR + Green}$	NIR, Green	Sí	Sí	Contenido hídrico superficial

Tabla 4
Abreviaturas utilizadas en figuras y resultados

Sigla	Nombre completo	Tipo
pH	Potencial de hidrógeno	Suelo
CE	Conductividad eléctrica	Suelo
N	Nitrógeno total	Suelo
P	Fósforo disponible	Suelo
K	Potasio intercambiable	Suelo
SOC	Carbono orgánico del suelo	Suelo
NDVI	Normalized Difference Vegetation Index	Índice
GNDVI	Green Normalized Difference Vegetation Index	Índice
NDRE	Normalized Difference Red Edge Index	Índice
SAVI	Soil Adjusted Vegetation Index	Índice
OSAVI	Optimized Soil Adjusted Vegetation Index	Índice
EVI2	Enhanced Vegetation Index 2	Índice
Cgreen	Chlorophyll Index Green	Índice
LCI	Leaf Chlorophyll Index	Índice
Blue	Banda azul	Banda
Green	Banda verde	Banda
Red	Banda roja	Banda
RedEdge	Banda red edge	Banda
NIR	Banda infrarrojo cercano	Banda
R ²	Coefficiente de determinación	Estadístico
RMSE	Root Mean Square Error	Estadístico
MAE	Mean Absolute Error	Estadístico

Tabla 5
Configuración de los modelos predictivos

Modelo	Variables de entrada	Estrategia de selección	Partición / validación	Hiper-parámetros	Métricas de evaluación	Variables objetivo
Regresión lineal múltiple (MLR)	Índices espectrales seleccionados (NDVI, NDRE, GNDVI, OSAVI)	Stepwise basado en AIC y VIF < 5	Holdout 70/30	No aplica	R ² train, R ² test, RMSE, MAE	pH, CE, N, P, K

Tabla 6
Parámetros del variograma y validación geoestadística

Variable	Componente	Modelo de variograma	Nugget	Sill	Range (m)	RMSE validación	Observación
pH	Multicultivo	Esférico	0,10	0,45	120	0,25	Variabilidad moderada, estructura espacial definida
CE	Multicultivo	Exponencial	0,15	0,60	95	0,30	Alta heterogeneidad, fuerte efecto local
P	Multicultivo	Gaussiano	0,20	0,75	80	0,35	Alta variabilidad, distribución irregular
Arcilla	Multicultivo	Esférico	0,12	0,50	140	0,28	Estructura espacial estable
N	Arroz	Esférico	0,05	0,40	60	0,18	Alta continuidad espacial, sistema homogéneo
P	Arroz	Exponencial	0,08	0,55	70	0,22	Variabilidad controlada por manejo
SOC	Arroz	Gaussiano	0,06	0,48	65	0,20	Distribución homogénea en parcelas
Limo	Arroz	Esférico	0,07	0,42	75	0,19	Textura relativamente uniforme

3. Resultados y discusión

3.1. Variabilidad descriptiva del suelo

La variabilidad descriptiva confirmó dos comportamientos claramente diferenciados entre los componentes evaluados. El sistema multicultivo presentó mayor heterogeneidad química y textural, con coeficientes de variación de 110,92 % para P, 79,26 % para N y 76,14 % para CE, mientras que el sistema arrocero mostró una mayor estabilidad relativa en variables como pH, SOC, K y arcilla, con CV de 4,80 %, 13,46 %, 18,76 % y 13,64 %, respectivamente (Tabla 7). Este patrón indica que el componente multicultivo operó como un entorno espacialmente más complejo, con mayor amplitud de respuesta edáfica y, por tanto, con mayor potencial para análisis de zonificación, mientras que el sistema arrocero ofreció una base más controlada para evaluar asociaciones entre información espectral y atributos del suelo bajo condiciones agronómicas más homogéneas. Esta diferencia da a entender que un mismo flujo analítico puede comportarse de manera distinta según la estructura espacial del sistema. Esta lectura es consistente con la literatura reciente sobre agricultura de precisión, donde la heterogeneidad intrapredial, la calidad del muestreo y la configuración del contexto productivo aparecen como factores decisivos para el rendimiento analítico y la utilidad agronómica de los resultados. Gade et al. documentaron 100 estudios y señalaron que la precisión depende de la integración entre sensor, variable y contexto; Peticilă et al. sintetizaron 472 publicaciones y confirmaron que NDVI, NDRE y GNDVI dominan la literatura, aunque con desempeño dependiente del entorno; y Saha et al. añadieron que la predicción mejora cuando se incorporan diseños híbridos y control explícito de la intravariabilidad (Gade et al., 2025; Peticilă et al., 2025; Saha et al., 2025).

3.2. Diferencias por cultivo, escala y densidad

Las diferencias según cultivo, escala y condición de manejo reforzaron la existencia de contrastes

edáficos importantes entre los componentes. El arroz presentó una conductividad eléctrica bastante más alta que el maíz, los pastos y otros usos, con $21,32 \pm 9,73$ mS/m frente a $5,50 \pm 1,13$ mS/m en maíz y $9,54 \pm 6,70$ mS/m en pastos y forrajes. En cambio, el maíz mostró mayor proporción de arena y menor contenido de arcilla en comparación con el arroz. A su vez, el fósforo disponible resultó más alto en maíz que en los demás usos ($57,98 \pm 33,30$ ppm frente a $16,91 \pm 10,52$ ppm en otros cultivos), mientras que el pH no mostró diferencias significativas entre grupos. Pues desde el punto de vista agronómico, este patrón sugiere tres procesos que ocurren al mismo tiempo: acumulación relativa de sales en zonas con manejo hídrico más permanente, diferencias texturales ligadas a la microtopografía y al uso del suelo, y un enriquecimiento localizado de P como respuesta al manejo diferencial o a la historia de fertilización. Más allá de la simple comparación de medias, estos resultados muestran que ambos componentes no solo se diferencian por el cultivo, sino también por su organización espacial y su dinámica de manejo. Eso condiciona la estabilidad de las relaciones espectrales y la capacidad de representar el suelo. Las diferencias observadas refuerzan que la comparación predictiva había que interpretarla sobre bases estructuralmente distintas, pero analíticamente homogéneas, es decir, aplicando el mismo flujo metodológico en sistemas con niveles contrastantes de heterogeneidad (Tabla 8).

3.3. Relaciones entre atributos del suelo e información espectral

La matriz de correlación de Spearman mostró que las asociaciones entre atributos del suelo e información espectral no fueron uniformes entre componentes, lo que refleja nuevamente la influencia de la heterogeneidad estructural sobre la estabilidad de la señal analítica (Figura 2).

En el componente multicultivo, EVI2 presentó correlaciones positivas altas con N y P, con $r = 0,85$

por $r = 0,82$, GDVI se asoció con limo y SOC, con $r = 0,84$ y $r = 0,79$, y NDVI y GNDVI mantuvieron relaciones moderadas con pH y K, con r entre 0,60 y 0,65; en el sistema arrocero, en cambio, las asociaciones más consistentes se concentraron en CE con NDVI y OSAVI, en P con GNDVI, NDRE y OSAVI, y en N con NDVI. Estos resultados indican que los índices basados en NIR y Red Edge captaron con mayor sensibilidad variables ligadas a fertilidad residual, salinidad y fracciones finas, aunque con diferente estabilidad según el sistema evaluado: en el arroz, la homogeneidad de cobertura y manejo favoreció asociaciones más consistentes, mientras que en multicultivo la coexistencia de coberturas, texturas y estados agronómicos diversos debilitó algunas relaciones químicas, pero mantuvo utilidad para detectar tendencias espaciales. Estas asociaciones constituyeron la base para la selección de predictores dentro del esquema MLR aplicado de forma consistente en ambos componentes, por lo que su interpretación no debe entenderse como un fin aislado, sino como un insumo técnico para el modelado posterior. Esta lectura es congruente con la literatura reciente. **Zhang et al. (2025a)** reportaron que NDVI, GNDVI y SAVI tienen aplicaciones maduras, mientras la integración de índices emergentes mejora la precisión; **Liang et al. (2025)** mostraron que NDRE y TCI/OSAVI fueron variables influyentes en modelos XGBoost con $R^2 = 0,83$ y que incorporar variables meteorológicas elevó la precisión entre 10,7% y 12,9%; **Quille et al.**

(2025) obtuvieron en Perú R^2 de 0,69 a 0,78 con índices espectrales y texturales en arroz; **Zhang et al. (2025a)** alcanzaron $R^2 = 0,86$ y $RMSE = 0,59$ t/ha con random forest en arroz japónica; **Tripathi et al. (2025)** reportaron $RMSE = 0,27$ t/ha con random forest usando UAV RGB; Mena et al. mostraron que la fusión multimodal elevó el rendimiento a $R^2 = 0,68$ a nivel subfield y cerca de 0,80 a nivel de campo; y **Jhajharia et al. (2025)** reforzaron que la combinación de sensores remotos con algoritmos supervisados mejora la predicción frente a enfoques estándar.

3.4. Desempeño comparativo de modelos

Bajo un mismo flujo analítico basado en MLR con selección stepwise, el sistema arrocero presentó mayores ajustes predictivos para variables específicas, mientras que el componente multicultivo mostró desempeños más modestos en estimación puntual, pero suficiente sensibilidad para aportar tendencias espaciales útiles. En arroz, los mayores ajustes dentro del esquema MLR se observaron para N con R^2 de prueba de 0,93, P con 0,88 y limo con 0,88, con R^2 de entrenamiento de 0,86, 0,50 y 0,59, respectivamente; en multicultivo, los mayores R^2 de prueba correspondieron a CE con 0,42, limo con 0,37 y pH con 0,34, mientras que el resto de variables permaneció en 0,27 o menos, con 0,23 para K, 0,16 para SOC, 0,12 para arena, 0,10 para N y 0,07 para P (Tabla 9).

Tabla 7
Estadísticos descriptivos de propiedades del suelo por componente del estudio

Variable	Multicultivo media ± DE	Multicultivo mínimo– máximo	Arroz media ± DE	Arroz mínimo– máximo	CV % multicultivo	CV % arroz
Limo (%)	16,61 ± 5,81	5,93–36,22	15,40 ± 6,38	6,00–40,00*	35,04	41,44
Arcilla (%)	50,77 ± 10,56	24,47–72,79	51,90 ± 7,08	30,00–60,00*	20,80	13,64
Arena (%)	32,63 ± 9,98	14,32–61,82	32,71 ± 5,02	25,00–45,00*	30,57	15,36
CE (mS/m)	11,01 ± 8,38	3,80–38,80	22,94 ± 6,29	17,50–27,50*	76,14	27,42
N (%)	2,30 ± 1,20	0,07–3,60	0,15 ± 0,03	0,12–0,18*	79,26	21,87
P (ppm)	37,83 ± 41,97	2,20–176,00	24,75 ± 16,16	18,00–32,00*	110,92	65,29
K (ppm)	367,10 ± 96,55	150,80–555,90	425,40 ± 79,81	380,00–450,00*	26,30	18,76
SOC (g/kg)	19,10 ± 3,88	9,00–23,70	15,67 ± 2,11	14,00–19,00*	20,29	13,46
pH	6,60 ± 0,57	5,20–7,50	6,98 ± 0,34	6,70–7,20*	8,64	4,80

Tabla 8
Comparación estadística de variables del suelo por componente y densidad

Variable	Prueba utilizada	p-valor	Diferencias significativas	Interpretación agronómica breve
CE	Kruskal–Wallis	<0,05	Arroz > maíz, pastos y otros	Señal de acumulación salina y efecto del manejo hídrico
Arena	Kruskal–Wallis	<0,05	Maíz y otros > arroz	Mayor fracción gruesa en usos no arroceros
Arcilla	Kruskal–Wallis	<0,05	Arroz y pastos > maíz y otros	Retención hídrica y textura fina más marcada
P	Kruskal–Wallis	<0,05	Maíz > otros; arroz intermedio	Respuesta a fertilización localizada
pH	Kruskal–Wallis	>0,05	Sin diferencias significativas	Estabilidad relativa entre usos
K	Kruskal–Wallis	>0,05	Sin diferencias significativas	Menor sensibilidad entre usos en este conjunto
N	Kruskal–Wallis	>0,05	Sin diferencias significativas	Alta variabilidad interna, sin separación robusta por cultivo
SOC	Kruskal–Wallis	>0,05	Sin diferencias significativas	Reserva orgánica relativamente estable

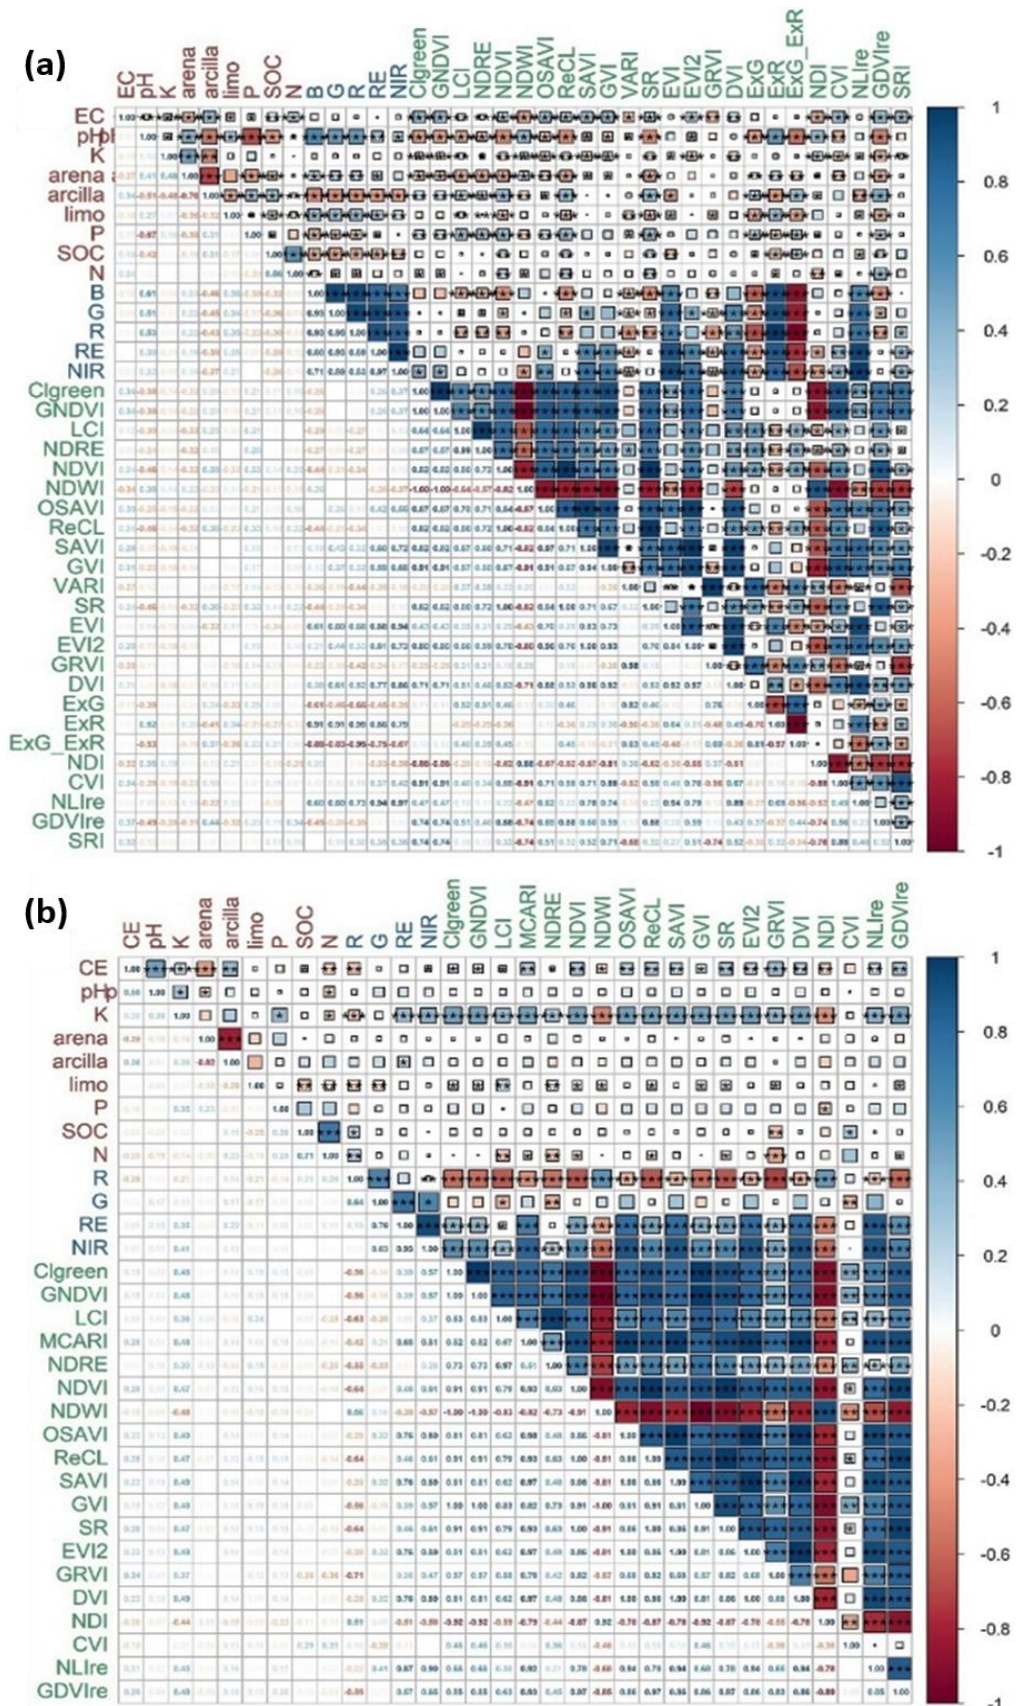


Figura 2. Análisis de correlación de Spearman en (a) multicultivo a escala de estación y (b) arrozero con diferentes densidades de siembra.

Tabla 9
Desempeño comparativo de los modelos por variable y componente

Variable	Componente	Mejor modelo	Índices espectrales seleccionados	n entrena- miento	n prueba	R ² entrena- miento	R ² prueba	RMSE	MAE
CE	Multicultivo	MLR stepwise	SAVI, OSAVI, EVI2, índices NIR derivados	42	18	0,50	0,42	9,91	6,85
pH	Multicultivo	MLR stepwise	NDVI, GNDVI, índices visibles-NIR	42	18	0,44	0,34	0,72	0,64
N	Multicultivo	MLR stepwise	NDVI, SR, GDVire	42	18	0,57	0,10	1,20	0,95
P	Multicultivo	MLR stepwise	NDRE, GNDVI, EVI2	42	18	0,40	0,07	49,22	41,21
K	Multicultivo	MLR stepwise	SAVI, OSAVI, EVI2	42	18	0,60	0,23	332,53	163,87
SOC	Multicultivo	MLR stepwise	GDVire, SAVI, EVI2	42	18	0,55	0,16	3,63	2,36
Arena	Multicultivo	MLR stepwise	NDVI, GNDVI, OSAVI	42	18	0,35	0,12	9,91	8,04
Arcilla	Multicultivo	MLR stepwise	ReCL, GDVire, índices red edge	42	18	0,40	0,27	10,97	10,27
Limo	Multicultivo	MLR stepwise	GDVire, ReCL, EVI2	42	18	0,59	0,37	16,26	10,45
CE	Arroz	MLR stepwise	NDVI, GNDVI, SR, EVI2, GDVire, SRI	20	7	0,85	0,51	12,16	10,97
pH	Arroz	MLR stepwise	NDVI, GNDVI, EVI2	20	7	0,85	0,65	4,16	2,88
N	Arroz	MLR stepwise	NDVI, GNDVI, EVI2, SR	20	7	0,86	0,93	0,07	0,05
P	Arroz	MLR stepwise	NDRE, GNDVI, EVI2, SRI	20	7	0,50	0,88	13,36	9,63
K	Arroz	MLR stepwise	NDVI, GNDVI, GDVire	20	7	0,55	0,67	233,51	153,36
SOC	Arroz	MLR stepwise	GDVire, SRI, EVI2	20	7	0,85	0,50	18,20	11,13
Arena	Arroz	MLR stepwise	NDVI, GNDVI, GDVire, SR	20	7	0,61	0,62	23,25	19,64
Arcilla	Arroz	MLR stepwise	ReCL, GDVire	20	7	0,69	0,66	19,78	16,04
Limo	Arroz	MLR stepwise	GDVire, SRI, ReCL	20	7	0,59	0,88	7,81	6,78

Esta diferencia indica que el desempeño no dependió únicamente de la estructura del modelo, sino de la heterogeneidad del sistema, la calidad espectral disponible, la densidad de muestreo y el grado de homogeneidad agronómica del contexto evaluado. En otras palabras, el sistema arrocero funcionó como entorno más favorable para predicción local bajo condiciones relativamente controladas, mientras que el multicultivo expresó una señal más compleja y menos estable para inferencia numérica directa. Esta interpretación es consistente con la literatura reciente. **Liang et al. (2025)** reportaron en arroz un R² de 0,83 con XGBoost al integrar índices multitemporales y variables meteorológicas; **Zhang et al. (2025a)** alcanzaron R² de 0,86 y RMSE de 0,59 t/ha con random forest en arroz japónica; **Quille et al. (2025)** obtuvieron en Lambayeque R² de 0,69 a 0,78 con índices espectrales y texturales; y **Tripathi et al. (2025)** reportaron RMSE de 0,27 t/ha con random forest usando UAV RGB. **Gade et al. (2025)** sintetizaron 100 estudios y concluyeron que la exactitud depende de la integración entre plataforma, sensor, variables y contexto agronómico, mientras **Saha et al. (2025)** destacaron que los mejores resultados emergen cuando se controlan simultáneamente intravariabilidad, calidad del muestreo y combinación multimodal de datos. El hallazgo central es la

evidencia de que, bajo un mismo flujo analítico, los sistemas homogéneos favorecieron la estimación puntual y los sistemas heterogéneos redujeron el ajuste numérico, aunque mantuvieron valor operativo para interpretación espacial.

3.5. Patrones espaciales y zonificación

La cartografía generada mediante kriging ordinario complementó la evaluación del desempeño predictivo puntual y permitió distinguir con claridad entre precisión numérica y utilidad espacial operativa. En el componente multicultivo, los mapas mostraron arcilla dominante entre 37,51% y 63,78%, limo entre 5,94% y 36,20%, arena entre 22,33% y 44,59%, CE entre 5,21 y 31,06 mS/m, y P entre 8,97 y 126,65 ppm, con parches espaciales marcados y focos localizados de salinidad y enriquecimiento fosfatado; este patrón confirmó que la principal utilidad del componente station-wide no fue la predicción exacta de cada punto, sino la identificación de zonas extremas para priorización de muestreo, ajuste de fertilización y delimitación de áreas con textura o salinidad diferenciada (**Figura 3**). En arroz, el kriging ordinario mostró concordancia espacial más estrecha para limo, arcilla y fósforo, mientras que CE y K presentaron una mayor suavización respecto de la variabilidad observada, comportamiento esperable cuando la heterogeneidad local supera la

densidad de puntos y el interpolador privilegia continuidad sobre detalle puntual. Desde una lectura agronómica (Figura 4), en multicultivo CE y P delimitaron sectores que requieren vigilancia de salinidad y balance fosfatado, mientras que en arroz (Figura 3), N y P permitieron distinguir zonas de manejo diferencial con utilidad para fertilización localizada y seguimiento de densidad de siembra. En este sentido, el componente multicultivo mostró menor ajuste puntual pero mayor valor para zonificación, mientras que el arroz mostró el patrón inverso, es decir, mejor capacidad de estimación

puntual y superficies más coherentes con manejo localizado. Esta interpretación coincide con la literatura reciente sobre agricultura de precisión. Mena et al. (2025) mostraron que la fusión multimodal mejora la predicción subfield hasta R^2 de 0,68 y cerca de 0,80 a nivel de campo porque integra distintas fuentes y conserva el valor espacial del dato, mientras que Gade et al. (2025) y colaboradores subrayan que la utilidad operativa de UAV no depende solo de maximizar R^2 , sino de producir superficies accionables para decisión agronómica.

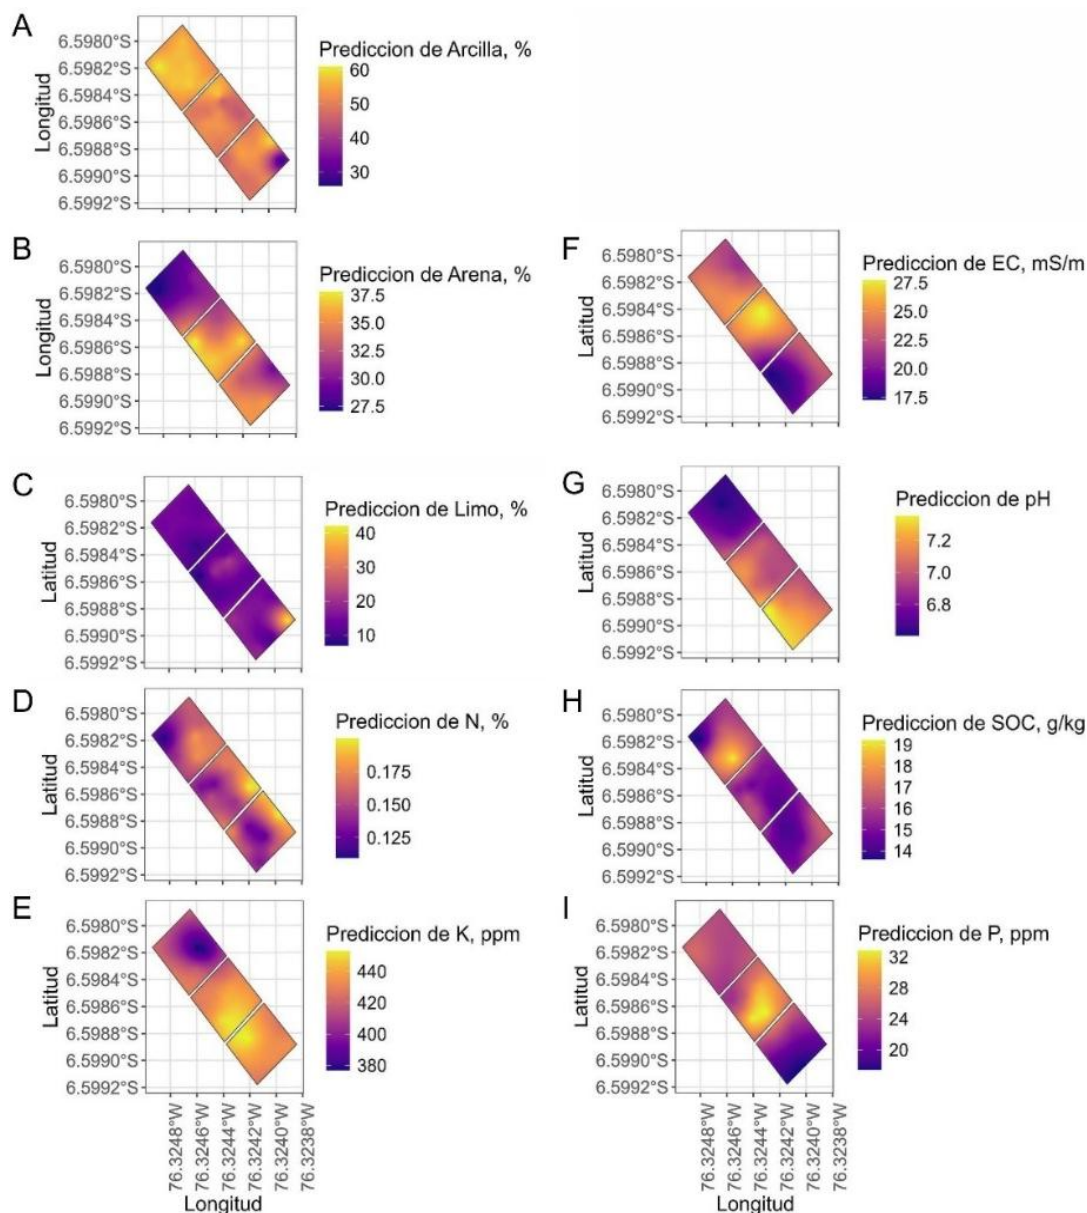


Figura 3. Distribución espacial de parámetros físicos y químicos del suelo: a) Arcilla, b) Arena, c) Limo, d) Nitrógeno, e) Potasio, f) Conductividad eléctrica, g) pH, h) Carbono orgánico del suelo (SOC), i) Fósforo en monocultivo arrocero con diferentes densidades de siembra.

Bajo un mismo flujo analítico, el mosaico multicultivo (Figura 4) redujo el ajuste numérico porque integró suelos, coberturas, manejos y gradientes texturales distintos dentro de una sola superficie analítica; sin embargo, esa misma complejidad incrementó su valor cartográfico al permitir delimitar zonas con extremos de CE, P y textura, útiles para priorización de muestreo, fertilización y drenaje. En contraste, el sistema arrocerero (Figura 3), al operar sobre parcelas más homogéneas y con manejo más controlado, favoreció relaciones espectrales más consistentes y mayores ajustes para N, P y limo. Esta diferencia tiene implicancias metodológicas y agronómicas para el uso de UAV en agricultura de precisión tropical,

porque muestra que los sistemas homogéneos favorecieron la estimación puntual, mientras que los sistemas heterogéneos favorecieron la delimitación operativa de unidades de manejo. Los antecedentes recientes refuerzan esta interpretación (Tabla 10): Liang et al. (2025) obtuvieron R^2 de 0,83 con XGBoost y datos multitemporales; Zhang et al. (2025a) alcanzaron R^2 de 0,86 con random forest; Quille et al. (2025) mostraron en Perú que los índices espectrales y texturales pueden sostener R^2 de 0,69 a 0,78; y Ma et al. (2026) demostraron que la integración de UAV, suelo, meteorología y manejo mejora la estimación del índice de nutrición nitrogenada mediante ensemble learning.

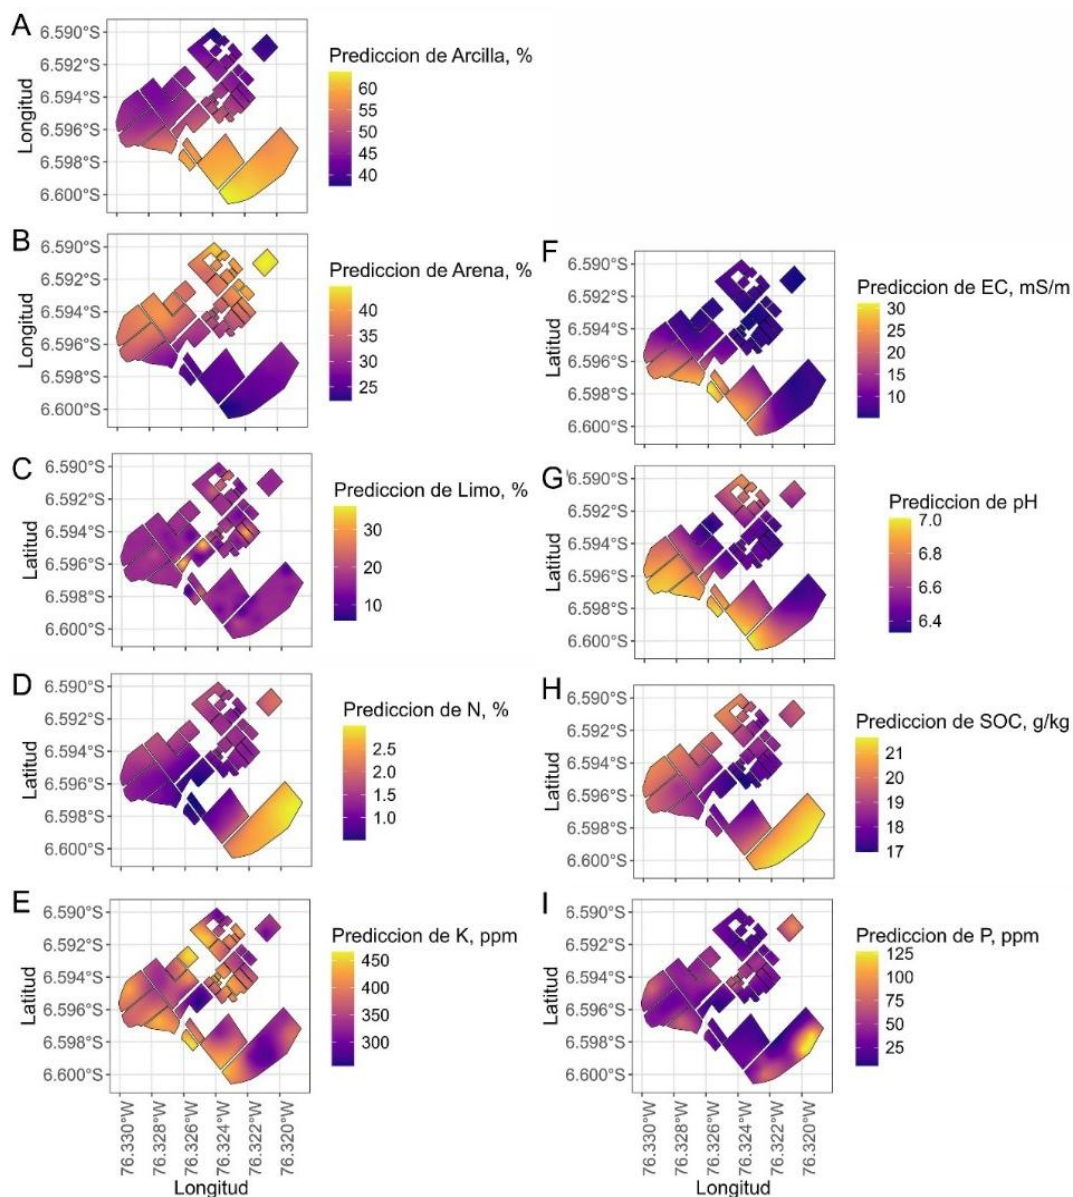


Figura 4. Distribución espacial de parámetros físicos del suelo. a) arcilla, b) arena, c) limo, d) nitrógeno, e) potasio, f) conductividad eléctrica, g) pH, h) carbón orgánico del suelo (SOC) y i) fósforo en sistema multicultivo a escala de estación.

Tabla 10
Comparación de estudios recientes sobre UAV, modelado predictivo y utilidad agronómica en agricultura de precisión

Estudio	Contexto	Objetivo principal	Datos y sensor	Modelo(s)	Variable objetivo	Hallazgos
Liang et al. (2025)	China, tres zonas agroecológicas, arroz	Predecir rendimiento con datos multitemporales	UAV multiespectral, 69 índices, 10 variables meteorológicas, tres cultivos, 2022 a 2024	SLR, PLSR, RF, GPR, SVM, XGB	Rendimiento	XGB obtuvo $R^2 = 0,83$; integrar meteorología mejoró precisión entre 10,7 % y 12,9 %
Gade et al. (2025)	Revisión global, 100 estudios	Revisar plataformas, sensores y analítica UAV para estimación de rendimiento	UAV, sensores múltiples, ML, fotogrametría, índices	Revisión	Rendimiento	NDVI apareció en 60 estudios; RF y regresión lineal emergen como opciones confiables para trigo, arroz y maíz
Zhang et al. (2025)	Revisión de agricultura de precisión	Sintetizar avances de UAV multiespectral	UAV multiespectral	Revisión	Monitoreo de crecimiento, plagas, nutrición y rendimiento	Los índices tradicionales como NDVI, GNDVI y SAVI tienen aplicación madura; índices emergentes más algoritmos inteligentes elevan precisión
Quille et al. (2025)	Perú, Lambayeque, arroz comercial	Predecir rendimiento con índices espectrales y texturales	Siete vuelos en 2022 y diez en 2023; UAV; índices espectrales y GLCM	MLR, SVR, RF	Rendimiento	MLR logró $R^2 = 0,69$ en floración y leche y $R^2 = 0,78$ en masa en 2022; RF obtuvo $R^2 = 0,58$ en análisis combinado 2022 a 2023
Zhang et al. (2025)	China, arroz japónica híbrido y convencional	Estimar rasgos fenotípicos y rendimiento	UAV multiespectral; seis experimentos con gradiente de fertilización	RF, XGBoost, SVR, BPNN, MLR	LAI, CC, PH, AGB y rendimiento	Correlaciones de LAI y CC $> 0,85$; RF logró $R^2 > 0,9$ para CC y $R^2 = 0,86$ para rendimiento con RMSE = 0,59 t/ha
Mena et al. (2025)	Argentina, Uruguay y Alemania; sub field	Fusionar datos remotos multimodales para predicción	Imágenes multiespectrales satelitales, clima, topografía y suelo	Multi modal gated fusion	Rendimiento	$R^2 = 0,68$ a nivel sub field y $\approx 0,80$ a nivel de campo
Tripathi et al. (2025)	India, arroz	Predecir rendimiento con UAV RGB y ML	UAV RGB; 25 índices, 17 retenidos con VIF	GBM, RF, ANN, SVM	Rendimiento	RF obtuvo RMSE = 0,27 t/ha; predicción entre 3,16 y 5,50 t/ha
Caroppo et al. (2026)	Revisión de datasets UAV	Revisar datasets multiespectrales disponibles para agricultura de precisión	39 datasets multiespectrales UAV	Revisión sistemática	Reproducibilidad y generalización	Detecta fuerte heterogeneidad en sensores, anotaciones, metadatos y calibración; la falta de estandarización limita reproducibilidad
Žydelis et al. (2026)	Lituania, croplands	Comparar predicción de propiedades del suelo con múltiples fuentes	UAV, satélite, EMI y ML	ML comparativo	Propiedades del suelo	Compara desempeño de varias fuentes para soil property prediction, mostrando que la precisión depende del tipo de dato y propiedad
Ma et al. (2026)	Arroz	Integrar UAV, variables ambientales y manejo	UAV + variables ambientales y de manejo	Ensemble learning	Índice de nutrición nitrogenada	Mejora la predicción del índice NNI integrando múltiples fuentes
Chen et al. (2024)	Bosque tropical lluvioso, China	Predecir propiedades del suelo indirectamente	UAV hiperespectral + LiDAR; 175 variables	ML	Propiedades del suelo	Integró 175 rasgos entre textura, índices y parámetros forestales para suelos tropicales

Otra posible explicación corresponde a la configuración instrumental, ya que el DJI Mavic 3M del componente multicultivo operó con cuatro bandas y sin azul, SWIR ni LWIR, mientras que el sistema arrocero utilizó MicaSense RedEdge-P con cinco bandas y GSD más fino; esta diferencia es una fuente plausible de variabilidad interpretativa, en línea con lo señalado por **Zhang et al. (2025b)** quienes mostraron que la precisión de UAV multispectral depende del sensor, del flujo de procesamiento, del fondo de suelo y de la arquitectura espectral.

Otra explicación corresponde a los límites del muestreo y del modelado: sesenta muestras para 60 ha en multicultivo y 27 puntos en arroz fueron suficientes para diagnóstico exploratorio y cartografía temática, pero siguen siendo modestos para aspirar a modelos universalizables; además, la ausencia de SWIR y LWIR restringió la captación de humedad, minerales y ciertos compuestos orgánicos, y los altos R^2 en arroz obligan a discutir riesgo de sobreajuste en ausencia de validación externa o multicampaña. En esa dirección, **Tripathi et al. (2025)** advirtieron que incluso modelos con buen RMSE requieren validación multilocal y multitemporal antes de su escalamiento; **Saha et al. (2025)** plantearon que la robustez futura depende de sistemas híbridos y control explícito de intravariabilidad; y **Mena et al. (2025)** mostraron que la ganancia real proviene de fusionar modalidades y no de depender de una sola fuente remota.

Los resultados permiten traducir el análisis en decisiones concretas de agricultura de precisión, en multicultivo, los mapas de CE, pH y limo sirven para priorizar muestreos de confirmación, identificar focos de salinidad y diferenciar zonas con distinta respuesta potencial a fertilización y drenaje; en arroz, las superficies de N, P y limo permiten orientar fertilización diferencial, ajustar densidades y concentrar el monitoreo en sectores con mayor riesgo de deficiencia o exceso.

4. Conclusiones

El presente estudio demostró que un mismo flujo analítico basado en imágenes UAV multispectrales, regresión lineal múltiple con selección de variables e interpolación geoestadística, produjo desempeños distintos según la heterogeneidad estructural del sistema evaluado, confirmando que la utilidad del enfoque depende del contexto productivo, de la escala de análisis y de la configuración instrumental empleada. En el componente arrocero, caracterizado por mayor homogeneidad agronómica y menor variabilidad espacial relativa, se observaron mejores niveles de predicción puntual para variables

específicas del suelo, mientras que en el componente multicultivo, donde coexistieron coberturas, manejos y condiciones edáficas más diversas, los ajustes numéricos fueron menores, pero la utilidad cartográfica fue mayor para la delimitación de zonas contrastantes y unidades de manejo. En ese sentido, los resultados muestran que el valor del enfoque no depende únicamente del R^2 alcanzado, sino también de su capacidad para generar información espacial operativa y agronómicamente accionable en sistemas tropicales. Asimismo, las diferencias en sensores y rangos espectrales contribuyeron a la variabilidad observada en el desempeño, lo que confirma que la selección instrumental condiciona la sensibilidad del análisis para captar propiedades edáficas indirectas.

El enfoque resultó más robusto como herramienta de diagnóstico espacial y apoyo a la agricultura de precisión que como sistema predictivo universal, por lo que futuras investigaciones deberían incrementar la densidad muestral, incorporar sensores con mayor cobertura espectral, incluyendo SWIR o sistemas hiperespectrales, integrar variables ambientales y de manejo, y validar los modelos en múltiples campañas y contextos para fortalecer su reproducibilidad, transferencia y escalabilidad en sistemas agrícolas tropicales complejos.

Contribución de los autores

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

ORCID

J. V. Megchun-García <https://orcid.org/0000-0002-2902-8088>
 S. Vega-Herrera <https://orcid.org/0000-0003-1930-1439>
 A. Ysuiza-Perez <https://orcid.org/0009-0006-9126-837X>
 M. Perez-Tello <https://orcid.org/0009-0001-8031-3714>
 D. Goigochea-Pinchi <https://orcid.org/0009-0001-4473-5936>
 R. Rios-Rios <https://orcid.org/0009-0004-3730-6852>
 P. Dominguez-Yap <https://orcid.org/0000-0002-2946-1383>
 L. Garcia <https://orcid.org/0000-0003-2371-8616>
 C. Barrera-Torres <https://orcid.org/0009-0005-6503-1398>
 C. Oliva-Cruz <https://orcid.org/0000-0003-1550-8977>
 M. Santillán-González <https://orcid.org/0009-0001-8791-7262>
 D. Arratea-Pillco <https://orcid.org/0000-0003-0703-2913>
 I. Alejos-Patiño <https://orcid.org/0000-0002-2549-5623>

Referencias bibliográficas

- Caroppo, A., Diraco, G., & Leone, A. (2026). A Systematic Review of Available Multispectral UAV Image Datasets for Precision Agriculture Applications. *Remote Sensing*, 18(4), 659. <https://doi.org/10.3390/rs18040659>
- Chen, Y., Shi, T., Li, Q., Yang, C., Wang, Z., Chen, Z., & Pan, X. (2024). Mapping Soil Properties in Tropical Rainforest Regions Using Integrated UAV-Based Hyperspectral Images and LiDAR Points. *Forests*, 15(12), 2222. <https://doi.org/10.3390/f15122222>
- EPA. (2004). *Method 9045D: Soil and Waste pH*. United States Environmental Protection Agency.
- Flores, R., Bahía, R. de C., Arévalo, Y., Torres, E. E., Guevara, J., Antezana, A., Carranza, A., Lao, C., & Solórzano-Acosta, R. (2025). Intermittent Rainfed Rice var. INIA 516 LM1: A Sustainable Alternative for the Huallaga River Basin. *Water*, 17(9), 1262. <https://doi.org/10.3390/w17091262>
- Gade, S. A., Madolli, M. J., García-Caparós, 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. *Remote Sensing Applications: Society and Environment*, 37, 101418. <https://doi.org/10.1016/j.rsase.2024.101418>
- Gee, G. W., & Or, D. (2002). Particle Size Analysis. In: Dane, J.H. and Topp, G.C., Eds., *Methods of Soil Analysis, Part 4, Physical Methods*, Soils Science Society of America, Book Series No. 5, Madison. *Soils Science Society of America*.
- ISO 11265. (1994). Soil quality - Determination of the specific electrical conductivity. *International Organization for Standardization*.
- 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*. <https://doi.org/10.47857/irjms.2025.v06i02.03182>
- Liang, Z., Fu, Z., Kiplagat, D., Wang, W., Yang, J., Li, Z., & Qiang Cao, Yongchao Tian, Yan Zhu, Weixing Cao, X. L. (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>
- Ma, Z., Xu, D., Qiu, Z., Fang, L., Wang, M., Wang, Z., Bao, R., Tang, Q., Song, X., Tan, C., & Li, Z. (2026). Integrating UAV, environmental, and management data to improve rice nitrogen nutrition index prediction using an ensemble learning algorithm. *BMC Plant Biology*. <https://doi.org/10.1186/s12870-026-08602-x>
- 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>
- MIDAGRI. (2025). *Observatorio de commodities arroz N.º 01 2025*. [https://repositorio.midagri.gob.pe/bitstream/20.500.13036/1984/1/Observatorio de commodities-arroz-n-01-2025.pdf](https://repositorio.midagri.gob.pe/bitstream/20.500.13036/1984/1/Observatorio%20de%20commodities-arroz-n-01-2025.pdf)
- Mulvaney, R. L. (1996). Part 3. Chemical methods. Nitrogen-Inorganic forms. *Methods of Soil Analysis*.
- Nelson, D. W., & Sommers, L. E. (2018). Total carbon, organic carbon, and organic matter. In *Methods of Soil Analysis, Part 3: Chemical Methods*. <https://doi.org/10.2136/sssabookser5.3.c34>
- Novais, J. J. M., Melo, B. M. D., Neves Junior, A. F., Lima, R. H. C., de Souza, R. E., Melo, V. F., do Amaral, E. F., Tziolas, N., & Dematté, J. A. M. (2025). Online analysis of Amazon's soils through reflectance spectroscopy and cloud computing can support policies and the sustainable development. *Journal of Environmental Management*, 375, 124155. <https://doi.org/10.1016/j.jenvman.2025.124155>
- Olsen, S. R., Cole, C. V., Watanabe, F., & Dean, L. (1954). Estimation of Available Phosphorus in Soil by Extraction with sodium Bicarbonate. Circular no. 939. Washington, D. C.
- 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. In *AgriEngineering*, 7(12), 431. <https://doi.org/10.3390/agriengineering7120431>
- Quille, J., Ramos, L., Huanqueño, J., Quispe, D., Cruz, L., Pino, E., Flores, L., Heros, E., & Ruiz, 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>
- Rhoades, J. D. (2018). Salinity: Electrical conductivity and total dissolved solids. In *Methods of Soil Analysis, Part 3: Chemical Methods*. <https://doi.org/10.2136/sssabookser5.3.c14>
- 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>
- SEMARNAT. (2002). Norma Oficial Mexicana NOM-021-RECNAT-2000, Que establece las especificaciones de fertilidad, salinidad y clasificación de suelos. Estudios, muestreo y análisis. *Diario Oficial de La Federación*.
- Solórzano, R., Cruz, J., Chuchon, R., Romero, L. E., Lozano, A., Gaona, N., & Vallejos, G. (2025). The conversion of forests to agricultural croplands significantly depletes soil organic carbon reserves, total nitrogen, and available potassium, reaching critical thresholds in the Peruvian Amazon. *Frontiers in Soil Science*, 5, 1662180. <https://doi.org/10.3389/fsoil.2025.1662180>
- Sparks D. L. (1996). Methods of soil analysis. Part 3-Chemical Methods. In *Soil Science Society of America Inc., American Society of Agronomy Inc.*
- Suleymanov, A., Komissarov, Mikhail Avizyan, M., Suleymanov, R., & Bikbaev, I. (2025). Unmanned Aerial Vehicles Applicability to Mapping Soil Properties Under Homogeneous Steppe Vegetation. *Land*, 14, 5. <https://doi.org/10.3390/land14050931>
- 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>
- USDA. (2025). Grain and feed annual: Peru, report PE2025 0008. In *Grain and feed annual: Peru, report PE2025 0008*.
- Vullaganti, N., Ram, B., & Sun, X. (2025). Precision agriculture technologies for soil site-specific nutrient management: A comprehensive review. *Artificial Intelligence in Agriculture*, 15(2), 147-161. <https://doi.org/10.1016/j.aiaa.2025.02.001>
- Zhang, L., Liang, X., Li, X., Zeng, K., Chen, Q., & Zhao, Z. (2025a). 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. (2025b). 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>
- Žydelis, R., Weihermüller, L., Gomes, L. C., Møller, A. B., Castaldi, F., et al. (2026). Comparison of soil property predictions in Lithuanian croplands using UAV, satellite, EMI data and machine learning. *Computers and Electronics in Agriculture*, 244(15), 111543. <https://doi.org/10.1016/j.compag.2026.111543>