

Monitoreo satelital del dosel de arroz mediante inteligencia artificial para la gestión sostenible de suelos en Venezuela

Satellite monitoring of rice canopy using artificial intelligence for sustainable soil management in Venezuela

Monitoramento do dossel do arroz por sensoriamento remoto e inteligência artificial para a gestão sustentável dos solos na Venezuela

Seijas César ^{1*}, Mikovic R. Frander ¹, Pérez Egilda ¹, Naranjo Isaac ²

¹ Centro de Procesamiento de Imágenes. Universidad de Carabobo, Naganagua 2005. Venezuela. ROR: <https://ror.org/05sj7yp62>

² Facultad de Ingeniería. Universidad José Antonio Páez, San Diego 2006. Venezuela. ROR: <https://ror.org/03d6w0229>

✉ cseijas@uc.edu.ve | ORCID: <https://orcid.org/0000-0001-6050-4436>

✉ fmikovic@uc.edu.ve | ORCID: <https://orcid.org/0009-0005-4052-3492>

✉ egiperez@uc.edu.ve | ORCID: <https://orcid.org/0000-0002-0633-8200>

✉ inaranjo21@ujap.edu.ve | ORCID: <https://orcid.org/0009-0007-6626-1085>

E-mail de correspondencia: cseijas@uc.edu.ve

Revista Saastal

Vol. 1(2) julio - diciembre 2025

<https://doi.org/10.63804/saastal.v1i2.e1>

Como citar este artículo

Seijas, C., Frander, M., Pérez, E., & Naranjo, I., (2025). *Monitoreo satelital del dosel de arroz mediante inteligencia artificial para la gestión sostenible de suelos en Venezuela*. Saastal, 1(2), e4.

© 2025 Saastal. Este es un artículo de acceso abierto distribuido bajo los términos de la licencia Creative Commons Attribution 4.0 International (CC BY 4.0), que permite el uso, distribución y reproducción sin restricciones en cualquier medio, siempre que se cite debidamente al autor y la fuente original.

Recibido: 15 de mayo de 2025

Revisado: 12 de junio de 2025

Aceptado: 25 de junio de 2025

Publicado: 10 de julio de 2025

Resumen

La gestión eficiente de los insumos agrícolas y la preservación de las propiedades edáficas constituyen pilares fundamentales para la sostenibilidad de los sistemas agroalimentarios modernos. Esta investigación diseñó y validó una metodología basada en Inteligencia Artificial (IA) orientada a la estimación de la cobertura del dosel en cultivos de arroz dentro de la región centro-occidental de Venezuela, empleando para ello datos radiométricos de la misión satelital Sentinel-2. El objetivo fue desarrollar un sistema de monitoreo no invasivo que permita optimizar la dosificación de fertilizantes nitrogenados, mitigando así el impacto ambiental y promoviendo la salud del suelo agrícola. La metodología se fundamentó en el entrenamiento de un modelo de Perceptrón Multicapa (MLP), cuya arquitectura fue optimizada para procesar firmas espectrales multitemporales. El rigor estadístico del modelo se garantizó mediante una validación cruzada de cinco pliegues, la cual reportó métricas de desempeño adecuadas, incluyendo un Error Cuadrático Medio (RMSE) promedio de 0,0071 y un coeficiente de determinación (R^2) de 0,9996. Adicionalmente, se ejecutó una fase de verificación externa que ratificó la capacidad de generalización del algoritmo en diversos escenarios fenológicos. Los resultados concluyen que la integración de redes neuronales artificiales y teledetección multiespectral permite una inferencia robusta de variables biofísicas, facilitando la toma de decisiones estratégicas en la agricultura de precisión. Esta aproximación técnica garantiza una mayor eficiencia productiva al tiempo que se posiciona como una herramienta para la monitorización de la salud edáfica y la reducción de la huella de carbono en la producción cerealera a gran escala.

Palabras clave: agricultura de precisión; arroz; fotogrametría; imágenes satelitales; percepción remota; teledetección.

Abstract

Efficient management of agricultural inputs and the preservation of soil properties are fundamental pillars for the sustainability of modern agri-food systems. This research designed and validated a methodology based on Artificial Intelligence (AI) aimed at estimating canopy cover in rice crops within the central-western region of Venezuela, using radiometric data from the Sentinel-2 satellite mission. The objective was to develop a non-invasive monitoring system capable of optimizing nitrogen fertilizer application, thereby mitigating environmental impact and promoting agricultural soil health. The methodology was based on training a Multilayer Perceptron (MLP) model, whose architecture was optimized to process multitemporal spectral signatures. The statistical rigor of the model was ensured through five-fold cross-validation, which reported strong performance metrics, including an average Root Mean Square Error (RMSE) of 0.0071 and a coefficient of determination (R^2) of 0.9996. Additionally, an external verification phase was conducted, confirming the algorithm's capacity to generalize across diverse phenological scenarios. The results conclude that the integration of artificial neural networks and multispectral remote sensing enables robust inference of biophysical variables, facilitating strategic decision-making in precision agriculture. This technical approach ensures greater production efficiency while positioning itself as a valuable tool for monitoring soil health and reducing the carbon footprint in large-scale cereal production.

Keywords: precision agriculture; rice; photogrammetry; satellite imagery; remote sensing; teledetection.

Resumo

A gestão eficiente dos insumos agrícolas e a preservação das propriedades do solo constituem pilares fundamentais para a sustentabilidade dos sistemas agroalimentares modernos. Esta pesquisa desenvolveu e validou uma metodologia baseada em Inteligência Artificial (IA) com o objetivo de estimar a cobertura do dossel em cultivos de arroz na região centro-ocidental da Venezuela, utilizando dados radiométricos da missão satelital Sentinel-2. O objetivo foi desenvolver um sistema de monitoramento não invasivo capaz de otimizar a aplicação de fertilizantes nitrogenados, mitigando assim o impacto ambiental e promovendo a saúde dos solos agrícolas. A metodologia baseou-se no treinamento de um modelo Multilayer Perceptron (MLP), cuja arquitetura foi otimizada para processar assinaturas espectrais multitemporais. O rigor estatístico do modelo foi assegurado por meio de validação cruzada de cinco dobras (five-fold cross-validation), que apresentou métricas de desempenho robustas, incluindo um erro quadrático médio da raiz (RMSE) de 0,0071 e um coeficiente de determinação (R^2) de 0,9996. Adicionalmente, foi realizada uma fase de verificação externa, confirmando a capacidade do algoritmo de generalizar em diferentes cenários fenológicos. Os resultados permitem concluir que a integração de redes neurais artificiais e sensoriamento remoto multiespectral possibilita a inferência robusta de variáveis biofísicas, facilitando a tomada de decisões estratégicas na agricultura de precisão. Essa abordagem técnica garante maior eficiência produtiva e posiciona-se como uma ferramenta valiosa para o monitoramento da saúde do solo e a redução da pegada de carbono na produção de cereais em larga escala.

Palavras-chave: agricultura de precisão; arroz; fotogrametria; imagens de satélite; sensoriamento remoto; teledeteção.

Introducción

La Agricultura de Precisión (AP) [1] se ha establecido como una estrategia técnico-científica empleada para mitigar los desafíos de la sostenibilidad y garantizar la seguridad alimentaria en el siglo XXI. En el contexto de Venezuela, el cultivo de arroz (*Oryza sativa*) representa un rubro estratégico para la dieta nacional; no obstante, su productividad enfrenta el reto de una optimización sistémica que demanda el uso eficiente de recursos críticos, tales como los nutrientes esenciales y el recurso hídrico. La transición hacia una agricultura inteligente requiere de herramientas que permitan monitorear el estado del cultivo en tiempo real para ajustar las intervenciones agronómicas a las necesidades espaciales específicas del terreno [2], [3].

En este escenario, la cobertura del dosel [4] se propone como un indicador biofísico que se correlaciona directamente con el índice de área foliar, el potencial de biomasa y la eficiencia fotosintética. Su monitoreo es particularmente importante para la gestión del Nitrógeno (N), elemento determinante en el desarrollo vegetativo. La aplicación empírica e ineficiente de fertilizantes nitrogenados desencadena un doble impacto negativo de proporciones considerables: por un lado, eleva los costos operativos de producción y, por otro, su uso excesivo genera desequilibrios ambientales que comprometen la salud del ecosistema edáfico. Estos incluyen la acidificación del sustrato, la degradación estructural de los suelos derivada de la lixiviación de nitratos hacia los horizontes inferiores y consecuentemente conlleva la eutrofización de cuerpos de agua circundantes. Por lo tanto, el incremento en la eficiencia del uso del nitrógeno (NUE) representa un imperativo ineludible de la ciencia del suelo contemporánea [5].

El avance disruptivo en la teledetección multiespectral [6] y la integración de la Inteligencia Artificial (IA) [7], [8] permiten superar las limitaciones intrínsecas de los métodos de muestreo tradicionales, los cuales suelen ser costosos, destructivos y carecen de representatividad espacial a gran escala. La capacidad de los algoritmos de aprendizaje automático para procesar firmas radiométricas complejas facilita la generación de mapas de prescripción de alta fidelidad para la fertilización de tasa variable. Esta precisión es importante puesto que maximiza el rendimiento y preserva las propiedades físico-químicas del suelo al promover la sostenibilidad agrícola en el largo plazo [9].

El objetivo de este trabajo fue desarrollar y validar un modelo computacional robusto para la estimación de la cobertura del dosel en cultivos de arroz, mediante la aplicación de técnicas de IA, específicamente un Perceptrón Multicapa (MLP), sobre imágenes del satélite Sentinel-

2 en la región centro-occidental de Venezuela. Se pretende que esta herramienta actúe como un proxy eficaz para la monitorización de la salud edáfica y sirva de base para una gestión sostenible que armonice la productividad cerealera con la protección del recurso suelo.

Metodología

Área de estudio y adquisición de datos

La investigación se desarrolló en el Sistema de Riego Río Guárico (SRRG), estado Guárico, Venezuela, una región estratégica donde aproximadamente el 50 % de las 35.000 hectáreas irrigadas se dedican exclusivamente a la producción de arroz. Para la estimación de la cobertura del dosel, se seleccionó como fuente sensorial única el satélite Sentinel-2 (Nivel L2A) [10]. Esta plataforma fue priorizada debido a que provee reflectancias superficiales con corrección atmosférica de fondo, una resolución espacial competitiva (10 a 20 metros) y una frecuencia de revisita de 5 días, factores que garantizan una base de datos de alta fidelidad para el entrenamiento de modelos de IA. Otras plataformas fueron descartadas por carecer de correcciones atmosféricas integradas o por presentar resoluciones temporales insuficientes para el monitoreo fenológico dinámico.

Construcción de la base de datos satelital

El flujo de procesamiento se ejecutó mediante la integración de Google Earth Engine (GEE) [11] y el lenguaje de programación Python [7]. En GEE, se delimitaron cinco parcelas representativas dentro del SRRG para la extracción de firmas espectrales. Se aplicó un filtrado de nubosidad (umbral ≤ 20 %) y las colecciones de imágenes fueron agrupadas por sellos temporales, seleccionando aquellas escenas con menor interferencia atmosférica para asegurar una serie temporal homogénea y estadísticamente significativa para el modelo.

Generación de la capa de etiquetas (Ground Truth)

La variable dependiente o capa de etiquetas (y) se generó a nivel de sub-imagen (parches de 32x32 píxeles) fundamentada en el Índice de Vegetación de Diferencia Normalizada (NDVI) [12], [13]. Se estableció un criterio de etiquetado por umbrales para discretizar la cobertura vegetal:

- $NDVI \leq 0,2$: Clasificado como cobertura nula (0).
- $NDVI \geq 0,7$: Clasificado como cobertura total (1).

- Para el rango intermedio se aplicó una interpolación lineal para normalizar los valores de cobertura, sirviendo esta capa como la referencia de “verdad de terreno” para la fase de aprendizaje supervisado.

Desarrollo y entrenamiento del modelo (MLP)

Se diseñó e implementó una Red Neuronal Profunda basada en una arquitectura de Perceptrón Multicapa (MLP) [7]. El modelo consta de dos capas densas ocultas y una capa de salida con función de activación Sigmoide, lo cual permite mapear la salida a un rango continuo entre 0 y 1. La variable de entrada (X) fue el valor de NDVI calculado a partir de las bandas B4 (Red) y B8 (NIR).

Para garantizar la capacidad de generalización y robustez del modelo, se empleó una técnica de validación cruzada de 5 pliegues (k-fold cross-validation). El proceso de optimización utilizó el algoritmo Adam y la función de pérdida de Error Cuadrático Medio (MSE). El desempeño fue evaluado en cada pliegue mediante métricas de error absoluto medio (MAE), error cuadrático medio (RMSE) y el coeficiente de determinación (R^2) [7].

Implementación y flujo de inferencia

Se desarrolló una herramienta modular en Python (3.8+) integrando librerías especializadas como rasterio para el manejo de datos geospaciales y TensorFlow/Keras para el despliegue del modelo. Esta herramienta permite la carga del MLP entrenado, el cálculo automatizado del NDVI a partir de nuevas imágenes en formato TIFF y la generación de un producto cartográfico de salida que predice la cobertura del dosel a escala de píxel, lo que facilitó su integración en sistemas de información geográfica (SIG) para la agricultura de precisión.

Resultados y discusión

Dinámica fenológica y consistencia de los datos satelitales

El análisis se fundamentó en la reflectancia de superficie de la misión Sentinel-2 L2A. La extracción automatizada mediante Google Earth Engine (GEE) garantizó una homogeneidad radiométrica crítica, manteniendo constantes los parámetros geométricos de adquisición (VZA: 9,0975°; VAA: 284,13°). Tras aplicar el filtrado por nubosidad, se consolidó un dataset de entre 21 y 24 escenas por parcela. Como se ilustra en la Figura 1, la serie temporal del NDVI refleja con precisión el ciclo biológico del arroz, mostrando el incremento de biomasa desde la fase de emergencia hasta alcanzar el máximo vegetativo cercano a 0,65 durante marzo de 2024, seguido por la senescencia característica previa a la cosecha.




Figura 1. Perfil temporal del índice NDVI para la parcela 251: Seguimiento fenológico del ciclo de cultivo (2024).

Evaluación cuantitativa del modelo MLP

El entrenamiento del Perceptrón Multicapa (MLP) mediante la variable “verdad de terreno” (*NDVI* normalizado entre 0,2 y 0,7) arrojó un desempeño adecuado. Según se detalla en la Tabla 1, el modelo alcanzó un coeficiente de determinación $R^2 = 0,9996$; lo que indica que el MLP explica casi la totalidad de la varianza del fenómeno. El error residual mínimo (RMSE = 0,0071) confirmó la alta fidelidad de la red para predecir la cobertura del dosel a partir de las bandas espectrales de Sentinel-2.

Tabla 1. Evaluación estadística del desempeño del modelo MLP mediante validación cruzada (5-folds).

Métrica	RMSE	MAE	R^2
Promedio sobre las parcelas en estudio	0,0071	0,0048	0,9996

RMSE: raíz del error cuadrático medio; MAE: error absoluto medio; R^2 : coeficiente de determinación.

Análisis espacial y validación de la regresión

La capacidad de inferencia a nivel de píxel se valida cualitativamente en la Figura 2, donde la distribución espacial del NDVI guarda una correlación directa con la cobertura estimada del dosel. Los patrones de variabilidad intra-parcelar detectados permiten identificar zonas de menor densidad foliar que podrían requerir ajustes en la fertilización nitrogenada.




Figura 2. Comparativa espacial entre el índice espectral NDVI (izquierda) y la cobertura del dosel predicha por el modelo MLP (derecha).

Asimismo, el gráfico de dispersión de la Figura 3 se muestra la precisión predictiva del sistema. La alineación casi perfecta de los datos sobre la diagonal ideal (línea de identidad) demuestra la ausencia de sesgos sistemáticos o heterocedasticidad en el modelo, incluso en los valores extremos de cobertura. La validación se complementó con análisis visuales en QGIS, donde métricas de segmentación como el Coeficiente Dice (0,86) y el IoU (0,84) confirmaron la robustez operativa de la arquitectura para aplicaciones de agricultura de precisión y monitoreo de la salud edáfica [7].




Figura 3. Validación de la linealidad y precisión del algoritmo de regresión.

Implicaciones para la sostenibilidad y la salud del suelo

La precisión del modelo MLP ($R^2 = 0,9996$) trasciende el ámbito técnico para convertirse en una herramienta crítica de sostenibilidad agrícola en la región centro-occidental de Venezuela. Al permitir una estimación espacialmente explícita de la cobertura del dosel a nivel de píxel (Figura 2), es posible transitar de esquemas de fertilización convencionales a una gestión de nutrición de tasa variable. Esta capacidad de prescripción asegura que la aplicación de fertilizantes nitrogenados se sincronice estrictamente con la demanda biofísica de la planta, minimizando el excedente de nitrógeno mineral en el perfil del suelo. Desde la perspectiva de la salud del suelo, esta optimización previene la acidificación progresiva del sustrato y reduce drásticamente los procesos de lixiviación de nitratos hacia los acuíferos locales, lo cual protege la estructura edáfica y la biodiversidad microbiana. En consecuencia, la metodología propuesta garantiza la rentabilidad del cultivo de arroz al tiempo que actúa como un mecanismo de mitigación ambiental, alineando la producción cerealera con los Objetivos de Desarrollo Sostenible y la preservación de los recursos naturales a largo plazo [14], [15].

Conclusiones

La presente investigación propone una metodología para el monitoreo biofísico del arroz, fundamentada en la integración de teledetección multiespectral e inteligencia artificial. Se delimitó y geolocalizó con éxito una base de datos satelital homogénea en el SRRG, cuya automatización mediante Google Earth Engine y la aplicación de criterios rigurosos de filtrado atmosférico garantizaron la obtención de series temporales de NDVI de alta fidelidad.

La implementación de la cobertura fraccional del dosel como una etiqueta continua en el rango $[0,1]$, derivada del procesamiento a nivel de píxel del NDVI, constituyó el núcleo de la estrategia de aprendizaje para el modelo de IA. El modelo de Perceptrón Multicapa (MLP) desarrollado exhibió una precisión excepcional y una estabilidad estadística sobresaliente bajo validación cruzada de 5 pliegues.

Al facilitar mapas de prescripción para la fertilización nitrogenada, el modelo contribuye directamente a prevenir la acidificación edáfica y la contaminación de acuíferos, alineando el desarrollo tecnológico con la preservación del ecosistema en la región centro-occidental de Venezuela.

Contribución y autoría

S.C.: Conceptualización, metodología, diseño de la arquitectura del Perceptrón Multicapa (MLP) y redacción del borrador original. **M.R.F.:** Desarrollo de software en Python, implementación del flujo de trabajo en Google Earth Engine (GEE) y procesamiento de imágenes Sentinel-2. **E.P.:** Curación de datos, análisis de validación cruzada (5-folds) e interpretación de las métricas de desempeño. **I.N.:** Validación externa en QGIS, supervisión técnica de la segmentación y revisión crítica del manuscrito final. Los autores declaran que han leído y aprobado la versión final del manuscrito.

Financiamiento

Este trabajo es financiado por el Ministerio del Poder Popular para Ciencia y Tecnología (MinCyT) bajo el proyecto titulado: *Consolidación del sistema inteligente para la estimación de la producción de arroz a nivel nacional*, coordinado por el Dr. César O. Seijas y alineado con el Plan de la Patria 2025.

Declaración ética

El estudio no involucró experimentación con seres humanos ni animales. Los datos satelitales utilizados son de acceso público (Programa Copernicus) y los datos de campo fueron procesados respetando la confidencialidad de los productores del Sistema de Riego Río Guárico.

Uso de inteligencia artificial

En este trabajo se empleó una red neuronal de tipo Perceptrón Multicapa (MLP) como núcleo del motor de inferencia para la estimación del dosel.

Disponibilidad de datos

El conjunto de datos multiespectrales de Sentinel-2 es de acceso público a través de la plataforma Google Earth Engine. El código fuente desarrollado en Python 3.8+, incluyendo los pesos del modelo MLP entrenado y los scripts de preprocesamiento, están disponibles para fines de reproducibilidad científica previa solicitud razonable al autor de correspondencia. Más información se puede requerir al autor de correspondencia.

Conflictos de intereses

Los autores declaran que no existen conflictos de intereses financieros, personales o profesionales que pudieran haber influido en el diseño de la metodología, la ejecución del experimento o la interpretación de los resultados de este artículo.

Referencias

- [1] E. M. B. M. Karunathilake, A. T. Le, S. Heo, Y. S. Chung, y S. Mansoor, «The Path to Smart Farming: Innovations and Opportunities in Precision Agriculture», *Agriculture*, vol. 13, n.º 8, p. 1593, ago. 2023, doi: 10.3390/agriculture13081593.
- [2] D. Li, T. Nanseki, Y. Chomei, y J. Kuang, «A review of smart agriculture and production practices in Japanese LARGE-SCALE rice farming», *J Sci Food Agric*, vol. 103, n.º 4, pp. 1609-1620, mar. 2023, doi: 10.1002/jsfa.12204.
- [3] H. Shahab, M. Naeem, M. Iqbal, M. Aqeel, y S. S. Ullah, «IoT-driven smart agricultural technology for real-time soil and crop optimization», *Smart Agricultural Technology*, vol. 10, p. 100847, mar. 2025, doi: 10.1016/j.atech.2025.100847.
- [4] B. Dechant *et al.*, «Canopy structure explains the relationship between photosynthesis and sun-induced chlorophyll fluorescence in crops», *Remote Sensing of Environment*, vol. 241, p. 111733, may 2020, doi: 10.1016/j.rse.2020.111733.
- [5] K. Chen *et al.*, «Effects of Water and Nitrogen Management on Water Productivity, Nitrogen Use Efficiency and Leaching Loss in Rice Paddies», *Water*, vol. 14, n.º 10, p. 1596, may 2022, doi: 10.3390/w14101596.
- [6] Y. Sato, T. Tsuji, y M. Matsuoka, «Estimation of Rice Plant Coverage Using Sentinel-2 Based on UAV-Observed Data», *Remote Sensing*, vol. 16, n.º 9, p. 1628, may 2024, doi: 10.3390/rs16091628.
- [7] F. Chollet, *Deep Learning with Python*, 2.^a ed. Shelter Island, NY: Manning Publications, 2021. [En línea]. Disponible en: <https://www.manning.com/books/deep-learning-with-python-second-edition>
- [8] I. Goodfellow, Y. Bengio, y A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016. [En línea]. Disponible en: <https://www.deeplearningbook.org>

- [9] D. Radočaj, M. Jurišić, y M. Gašparović, «The Role of Remote Sensing Data and Methods in a Modern Approach to Fertilization in Precision Agriculture», *Remote Sensing*, vol. 14, n.º 3, p. 778, feb. 2022, doi: 10.3390/rs14030778.
- [10] European Space Agency, «Overview of Sentinel-2 Mission». 2024. [En línea]. Disponible en: <https://sentiwiki.copernicus.eu/web/s2-mission#MSIInstrument>
- [11] Google, «Google Earth Engine». 2024. [En línea]. Disponible en: https://www.google.com/intl/es419_ALL/earth/education/google-earth-engine/
- [12] J. Weier y D. Herring, «Measuring Vegetation (NDVI & EVI)». 2000. [En línea]. Disponible en: <https://earthobservatory.nasa.gov/features/MeasuringVegetation>
- [13] T. N. Carlson y D. A. Ripley, «On the relation between NDVI, fractional vegetation cover, and leaf area index», *Remote Sensing of Environment*, vol. 62, n.º 3, pp. 241-252, dic. 1997, doi: 10.1016/S0034-4257(97)00104-1.
- [14] R. K. Srivastava, «Conservation Tillage Practices on GHG Emissions, Soil Health and Overall Agricultural Sustainability», *Soil Use and Management*, vol. 41, n.º 2, p. e70096, abr. 2025, doi: 10.1111/sum.70096.
- [15] S. S. Shah *et al.*, «Impact of irrigation, fertilizer, and pesticide management practices on groundwater and soil health in the rice–wheat cropping system—a comparison of conventional, resource conservation technologies and conservation agriculture», *Environ Sci Pollut Res*, vol. 32, n.º 2, pp. 533-558, dic. 2024, doi: 10.1007/s11356-024-35661-0.

Descargo de responsabilidad

Los artículos publicados en la revista **Saastal** representan únicamente las opiniones de los autores. La Editorial Unión Científica, su equipo editorial y sus revisores no se hacen responsables del contenido, las interpretaciones o las consecuencias derivadas de la aplicación de los métodos o conclusiones incluidas en los trabajos. Todas las publicaciones se rigen por las políticas éticas de la editorial.