

Procesamiento de imágenes espectrales y aprendizaje profundo para la identificación de cultivo de arroz

Spectral image processing and deep learning for rice crop identification

Processamento de imagens espectrais e aprendizado profundo para a identificação de cultivos de arroz

Egilda Pérez ^{1*}, Guillermo Montilla ², Seijas César ¹, Richard Barrios ¹

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

² Research and Development Dept., Yttrium Technology Corp, Houston, TX 77002. USA.

✉ egiperez@uc.edu.ve

| ORCID: <https://orcid.org/0000-0002-0633-8200>

✉ montillaleon@yttrium-technology.com

| ORCID: <https://orcid.org/0000-0002-1777-6353>

✉ cseijas@uc.edu.ve

| ORCID: <https://orcid.org/0000-0001-6050-4436>

✉ richbr2014@gmail.com

| ORCID: <https://orcid.org/0000-0002-3769-7898>

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

Revista Saastal

Resumen

Vol. 2(1) enero - junio 2026

<https://doi.org/10.63804/saastal.v2i1.e1>

Como citar este artículo

Pérez, E., Montilla, G., Seijas, C., & Barrios, R., (2025). *Procesamiento de imágenes espectrales y aprendizaje profundo para la identificación de cultivo de arroz*. *Saastal*, 2(1), e1.

© 2026 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: 10 de noviembre de 2025

Revisado: 05 de diciembre de 2025

Aceptado: 18 de diciembre de 2025

Publicado: 15 de enero de 2026

El monitoreo preciso de los ciclos agrícolas es necesario para garantizar la seguridad alimentaria y optimizar la gestión de recursos hídricos en regiones productoras de cereales. Esta investigación aborda la problemática de la clasificación automatizada de coberturas vegetales mediante el diseño y validación de un modelo avanzado de identificación de cultivos de arroz basado en el aprendizaje profundo y el procesamiento de imágenes satelitales multiespectrales. La metodología empleó una arquitectura de red neuronal convolucional, U-Net, optimizada para la segmentación semántica de datos geoespaciales provenientes de la misión Sentinel-2. Se procesaron tensores de entrada compuestos por cuatro bandas espectrales estratégicas, lo que permitió a la red generar máscaras binarias de alta precisión asociadas exclusivamente a las regiones de producción arroceras. El estudio integró una fase comparativa donde se evaluaron diversas configuraciones de hiperparámetros para determinar la arquitectura de mayor convergencia. Los resultados experimentales mostraron un rendimiento sobresaliente del modelo durante la fase de entrenamiento, con una exactitud del 92,3 %. Asimismo, la robustez de la segmentación fue validada mediante la métrica de Intersección sobre la Unión (IoU) con un 86 % y un coeficiente Dice del 89 %, valores que superan los umbrales convencionales en la identificación de cultivos complejos. Se concluye que la integración de arquitecturas U-Net con datos multiespectrales de libre acceso constituye una herramienta técnica viable y escalable para la teledetección agrícola de precisión. Estos resultados permiten proponer el modelo desarrollado como una solución eficiente para el inventario de cultivos a gran escala, como soporte para la toma de decisiones gubernamentales y la predicción de cosechas en entornos climáticos variables.

Palabras clave: agricultura; arroz; fotogrametría; percepción remota; tecnología de la información.

Abstract

Accurate monitoring of agricultural cycles is essential to ensure food security and optimize water resource management in cereal-producing regions. This research addresses the challenge of automated vegetation cover classification through the design and validation of an advanced rice crop identification model based on deep learning and the processing of multispectral satellite imagery. The methodology employed a convolutional neural network architecture, U-Net, optimized for the semantic segmentation of geospatial data obtained from the Sentinel-2 mission. Input tensors composed of four strategic spectral bands were processed, enabling the network to generate highly accurate binary masks associated exclusively with rice production areas. The study incorporated a comparative phase in which several hyperparameter configurations were evaluated to determine the architecture with the highest convergence. Experimental results showed outstanding model performance during the training phase, achieving an accuracy of 92.3 %. Furthermore, the robustness of the segmentation was validated using the Intersection over Union (IoU) metric with 86 % and a Dice coefficient of 89 %, values that exceed conventional thresholds for the identification of complex crops. It is concluded that the integration of U-Net architectures with openly accessible multispectral data constitutes a viable and scalable technical tool for precision agricultural remote sensing. These findings support proposing the developed model as an efficient solution for large-scale crop inventory, providing support for governmental decision-making and crop yield prediction in variable climatic environments.

Keywords: agriculture; rice; photogrammetry; remote sensing; information technology.

Resumo

O monitoramento preciso dos ciclos agrícolas é essencial para garantir a segurança alimentar e otimizar a gestão dos recursos hídricos em regiões produtoras de cereais. Esta pesquisa aborda o desafio da classificação automatizada da cobertura vegetal por meio do desenvolvimento e da validação de um modelo avançado de identificação de cultivos de arroz baseado em aprendizado profundo e no processamento de imagens de satélite multiespectrais. A metodologia empregou uma arquitetura de rede neural convolucional do tipo U-Net, otimizada para a segmentação semântica de dados geoespaciais obtidos pela missão Sentinel-2. Foram processados tensores de entrada compostos por quatro bandas espectrais estratégicas, permitindo que a rede gerasse máscaras binárias de alta precisão associadas exclusivamente às áreas de produção de arroz. O estudo incluiu uma etapa comparativa na qual diferentes configurações de hiperparâmetros foram avaliadas para determinar a arquitetura com maior capacidade de convergência. Os resultados experimentais demonstraram desempenho excepcional do modelo durante a fase de treinamento, alcançando uma acurácia de 92,3%. Além disso, a robustez da segmentação foi validada por meio da métrica Intersection over Union (IoU), com valor de 86%, e por um coeficiente Dice de 89%, resultados que superam os limiares convencionais para a identificação de culturas agrícolas complexas. Conclui-se que a integração de arquiteturas U-Net com dados multiespectrais de livre acesso constitui uma ferramenta técnica viável e escalável para o sensoriamento remoto aplicado à agricultura de precisão. Esses achados sustentam a proposta do modelo desenvolvido como uma solução eficiente para o inventário de cultivos em larga escala, fornecendo suporte à tomada de decisões governamentais e à previsão de rendimento agrícola em ambientes sujeitos à variabilidade climática.

Palavras-chave: agricultura; arroz; fotogrametria; sensoriamento remoto; tecnologia da informação.

Introducción

En la actualidad, los sistemas satelitales representan una infraestructura importante en la percepción remota debido a su capacidad para la monitorización multitemporal de extensas áreas geográficas. Con resoluciones espaciales que oscilan entre los 10 y 100 metros dependiendo de la plataforma, estos sistemas facilitan el seguimiento de dinámicas terrestres a gran escala; no obstante, su principal limitación técnica radica en la dependencia de condiciones climáticas y atmosféricas para la captura de datos ópticos de alta fidelidad [1]. A pesar de estos desafíos, el monitoreo de cultivos mediante sensores remotos se ha consolidado como un eje fundamental en el diseño de políticas públicas orientadas a la seguridad alimentaria. Los datos satelitales son componentes esenciales en el desarrollo de modelos predictivos para el pronóstico de rendimientos, la gestión optimizada de recursos hídricos y la regulación del control químico mediante el uso de fertilizantes. Asimismo, en contextos de variabilidad climática, desastres naturales o estrés por plagas, el registro histórico de imágenes permite realizar análisis comparativos multitemporales para la evaluación precisa de daños y la estimación de pérdidas económicas [2], [3].

En el contexto latinoamericano, la estimación de superficies cultivadas mediante técnicas de monitoreo tradicional y remoto ha sido liderada por instituciones como el Instituto Nacional de Estadística, Geografía e Informática (INEGI) en México, el Organismo Internacional Regional de Sanidad Agropecuaria (OIRSA), la Federación Nacional de Arroceros (Fedearroz) en Colombia, la Comisión Nacional de Actividades Espaciales (CONAE) en Argentina, el Ministerio de Desarrollo Agrario y Riego (MIDAGRI) en Perú y la Empresa Brasileña de Investigación Agropecuaria (Embrapa) en Brasil. Sin embargo, los métodos tradicionales de clasificación supervisada a menudo presentan limitaciones en la diferenciación de coberturas vegetales con firmas espectrales similares, especialmente en el cultivo de arroz, cuya fenología está estrechamente ligada a periodos de inundación que pueden confundirse con otros cuerpos de agua o humedales [4], [5].

Para superar estas limitaciones, la integración de técnicas de inteligencia artificial (IA) plantea una solución disruptiva. El presente trabajo se enfoca en la

identificación automatizada de cultivos de arroz mediante el procesamiento de datos satelitales multiespectrales de la plataforma Copernicus, específicamente utilizando el sensor MSI del satélite Sentinel-2, el cual proporciona 13 bandas espectrales de alta resolución [6], [7]. La investigación propone el despliegue de una arquitectura de aprendizaje profundo tipo U-Net, diseñada para la segmentación semántica compleja. Esta aproximación permite capturar no solo la información radiométrica por píxel, sino también patrones espaciales y contextuales, mejorando significativamente la precisión en la delimitación de parcelas agrícolas frente a los algoritmos de clasificación convencionales.

Metodología

Área de estudio y datos de referencia

La investigación se localiza en el estado de Rio Grande do Sul, Brasil, región de vital importancia para la producción de cereales en Sudamérica. Como fundamento para la supervisión del modelo, se utilizaron los conjuntos de datos de “verdad de terreno” (*ground truth*) e información estadística geoespacial proporcionados por la Compañía Nacional de Abastecimiento (Conab) de Brasil. El marco temporal del estudio abarcó los ciclos agrícolas correspondientes a los periodos 2019/2020 y 2022/2023, permitiendo capturar la variabilidad interanual de la respuesta espectral del cultivo de arroz.

Arquitectura de red neuronal convolucional U-Net

Se implementó una arquitectura U-Net, seleccionada por su eficiencia probada en tareas de segmentación semántica de imágenes biomédicas y geoespaciales. La red se caracteriza por su estructura simétrica de codificador-decodificador (*encoder-decoder*) con conexiones de salto (*skip connections*), lo que permite preservar la información espacial de alta resolución durante la reconstrucción de la máscara de salida. Los datos de entrada consisten en tensores multiespectrales provenientes de la plataforma Sentinel-2, integrando específicamente las bandas R (Red), G (Green), B (Blue) y NIR (Near-Infrared).

Como se detalla en la Figura 1, la arquitectura presenta una estructura simétrica compuesta por dos secciones principales:

- Encoder o ruta de contracción, se aplicó una serie de bloques convolucionales de 3×3 seguidos de activaciones ReLU y normalización por lotes (*Batch Normalization*), el codificador extrae características abstractas del cultivo mientras reduce la resolución espacial mediante operaciones de Max Pooling de 2×2 . Este proceso incrementa la profundidad de los mapas de características (desde 64 hasta 1024 canales) para capturar patrones radiométricos complejos.
- Decoder o ruta de expansión, se hizo mediante convoluciones transpuestas de 2×2 (*Up-convolution*), aquí, la red recupera la resolución espacial original. El factor distintivo de esta arquitectura son las conexiones de salto (*skip connections*) o concatenaciones, las cuales transfieren mapas de características de alta resolución desde el codificador directamente al decodificador. Esto permite que el modelo recupere detalles espaciales finos de las parcelas de arroz que se pierden durante la contracción.

Finalmente, una capa de convolución de 1×1 proyecta el vector de características resultante en una máscara binaria de salida, donde cada píxel es clasificado como región productora de arroz o fondo.




Figura 1. Arquitectura U-Net optimizada para la segmentación semántica de cultivos de arroz mediante datos de Sentinel-2.

La inclusión de la banda NIR es determinante, dado que permite discriminar la firma espectral de la vegetación densa y los niveles de humedad característicos de las zonas arroceras.

Justificación técnica de la arquitectura U-Net

La eficacia de la arquitectura U-Net en la identificación de parcelas agrícolas reside en la integración de las conexiones de salto entre las rutas de contracción y expansión. En el procesamiento de imágenes de Sentinel-2, estas conexiones permiten que la red recupere la información espacial de alta resolución y los detalles morfológicos de los cultivos que tienden a degradarse durante las operaciones de submuestreo (*downsampling*) en el codificador. Matemáticamente, la concatenación de mapas de características asegura que el decodificador disponga de descriptores granulares para una reconstrucción precisa de los límites de las parcelas de arroz, mitigando eficazmente el problema del desvanecimiento del gradiente.

En la capa de salida de la red, se implementó una función de activación Sigmoide (σ). Dado que el problema se define como una clasificación binaria (presencia o ausencia de cultivo), la función sigmoide es la opción óptima al mapear el valor logit resultante a un rango probabilístico (0,1) mediante la Ecuación 1:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad \text{Ecuación 1}$$

Este enfoque permite establecer un umbral de decisión crítico, donde cada píxel se asigna a la clase “arroz” si su probabilidad excede un valor predefinido (0,5), esto garantiza una segmentación semántica nítida y una interpretación directa de las regiones productoras frente al entorno circundante.

Procesamiento y modelado matemático

El propósito del sistema es la generación de una máscara binaria segmentada que identifique con precisión las regiones de cultivo. El proceso de aprendizaje de la red se fundamentó en la optimización de pesos sinápticos aplicados a las componentes espectrales de entrada. Matemáticamente, el modelo buscó minimizar una función

de costo y maximizar la probabilidad de pertenencia de un píxel a la clase “arroz” frente al fondo.

Desde una perspectiva estadística, los píxeles pertenecientes a la región de interés exhiben parámetros con una alta correlación espacial y agrupamiento jerárquico (θ) dentro del espacio de características. Por el contrario, los píxeles no pertenecientes a dicha clase se distribuyen de manera dispersa o atípica respecto a la distribución de probabilidad del modelo entrenado.

Estrategia de entrenamiento y validación

El conjunto de datos se fragmentó aleatoriamente en tres subconjuntos independientes: entrenamiento (70 %), validación (20 %) y prueba (10 %). Con el fin de disminuir el riesgo de sobreajuste (*overfitting*) y mejorar la capacidad de generalización del modelo, se aplicaron técnicas de aumento de datos (*Data Augmentation*), lo que incluyó rotaciones geométricas, inyección de ruido gaussiano (*Blur*) y variaciones controladas de opacidad [8], [9].

Para evaluar la robustez del modelo se hizo mediante una matriz de métricas de rendimiento que incluyó el Accuracy (Exactitud global), el Índice Jaccard (IoU), el Coeficiente Dice (F1-Score) y el análisis de la curva de la Función de Pérdida (*Loss Function*). Estas métricas garantizan una validación rigurosa de la bondad de ajuste del modelo en la delimitación de superficies agrícolas complejas.

Resultados

Dinámica de entrenamiento y convergencia del modelo

El entrenamiento de la arquitectura U-Net se ejecutó durante un máximo de 50 épocas, implementando una estrategia de parada temprana (*Early Stopping*) para prevenir el sobreajuste. Los hiperparámetros se configuraron con una tasa de aprendizaje de 1×10^{-4} y un tamaño de lote (*batch size*) de 4, utilizando la función de pérdida como indicador de monitoreo con un umbral de paciencia de 10 iteraciones sin mejora incremental.

Como se muestra en la Figura 2, tanto la exactitud (Accuracy) como el índice de Intersección sobre la Unión (IoU) muestran una convergencia asintótica estable a partir de la época 25.




Figura 2. Evolución de la exactitud e intersección sobre la Unión (IoU) durante 50 épocas de entrenamiento y validación.

La proximidad entre las curvas de entrenamiento y validación sugiere una alta capacidad de generalización del modelo. Específicamente, el sistema alcanzó una exactitud superior al 92 % y un IoU de validación que se estabiliza cerca del 80 %, lo que confirma la eficacia de la red en la segmentación de coberturas agrícolas complejas.

Por su parte, la Figura 3 ilustra la evolución del Coeficiente Dice y la función de pérdida (Loss). Se evidencia una reducción drástica de la pérdida en las fases iniciales, alcanzando niveles inferiores al 0,2 en el set de validación.




Figura 3. Estabilidad del coeficiente Dice frente al número de iteraciones bajo criterios de Early Stopping.

La robustez del modelo se ve reflejada en un coeficiente Dice de entrenamiento que bordea el 89%, validando la precisión de la red en la detección de la clase "arroz" frente a la variabilidad espectral del entorno.

Evaluación cualitativa y análisis de segmentación

La Figura 4 presenta la validación visual del modelo mediante tres muestras de prueba independientes, donde se comparan las imágenes originales, las máscaras de referencia (ground truth) y las predicciones generadas por la red.




Figura 4. Análisis de la precisión en bordes y morfología de parcelas mediante métricas de segmentación por píxel.

La evaluación cualitativa de los resultados, presentada en la Figura 4, permite analizar el desempeño del modelo a través de tres muestras de prueba representativas que evidencian la capacidad de generalización de la arquitectura propuesta. En la primera muestra (Accuracy de 0,9306), el modelo logra una identificación predominante de la morfología del cultivo, permitiendo reconocer la estructura general de la parcela, aunque se muestra la persistencia de pequeñas regiones de píxeles mal clasificados en las zonas periféricas del polígono.

En la segunda muestra (Accuracy de 0,9449), el sistema exhibe una delimitación significativamente más rigurosa de los bordes; no obstante, se identifica una dificultad característica en la definición de elementos lineales de baja reflectancia, tales como caminerías o bordes estrechos entre parcelas, lo cual sugiere la influencia de la resolución espacial en la segmentación de estructuras no vegetales.

Finalmente, la tercera muestra, representa el desempeño óptimo del sistema, ahí se alcanzó métricas de exactitud de 0,9653 e índice de intersección (IoU) de 0,9280. Estos resultados sobresalientes confirman la robustez de la arquitectura para capturar eficazmente tanto la textura como la firma espectral distintiva del arroz bajo condiciones de alta densidad, validando su eficacia operativa para la teledetección agrícola.

Discusión

Las limitaciones encontradas en la definición de bordes y caminos (Figura 4, Accuracy de 0,9449) coinciden con lo reportado en investigaciones previas, donde se atribuye este fenómeno a la resolución espacial nativa de 10 metros de Sentinel-2. Trabajos de referencia sugieren que la integración de imágenes de mayor resolución, como las de la constelación Planet (3-5 metros), podría mitigar estas inconsistencias [10], [11], [12]. Asimismo, la implementación de mecanismos de atención (*Attention Gates*) dentro de la arquitectura U-Net ha demostrado mejorar la discriminación de características finas, permitiendo que el modelo ignore ruidos de fondo no relevantes en el proceso de segmentación [13]. A pesar de estas áreas

de mejora, los resultados validan al modelo propuesto como una herramienta robusta y escalable para el inventario de cultivos a gran escala.

El análisis comparativo del rendimiento del modelo reveló que la implementación de técnicas de aumento de datos (*Data Augmentation*) es un factor crítico para la precisión de la segmentación en entornos agrícolas dinámicos. Como se detalla en la Tabla 1, la configuración U-Net_DA (con aumento de datos) superó consistentemente a la arquitectura base en todas las métricas, elevando el coeficiente IoU de 0,79 a 0,84; además, se redujo la función de pérdida a casi la mitad (0,07).

Tabla 1. Evaluación comparativa del rendimiento del modelo U-Net con y sin implementación de técnicas de aumento de datos.

Arquitectura	Accuracy	DICE	IoU	Loss_Dice
U-Net	0,92	0,83	0,79	0,13
U-Net_DA	0,96	0,86	0,84	0,07

Un resultado significativo se encontró en el porcentaje de imágenes no solapadas, un indicador inverso de la precisión cartográfica. Mientras que el entrenamiento convencional reportó un 13,82 % de inconsistencias en el solapamiento, el uso de transformaciones sintéticas en el dataset de entrenamiento permitió reducir este margen de error al 7,23 %. Este parámetro resulta importante para la generación de mapas de uso de suelo fiables, donde la delimitación exacta de las fronteras agrícolas determina la validez del inventario nacional de cultivos.

En términos de competitividad tecnológica, aplicaciones comerciales como DigiFarm reportan métricas de IoU cercanas al 98 %. Si bien el modelo propuesto presenta una brecha respecto a soluciones propietarias de alta gama, los resultados de este trabajo muestran que es posible alcanzar una solución técnica altamente rentable y escalable utilizando datos de acceso libre (Sentinel-2) y arquitecturas de código abierto.

La robustez del modelo desarrollado se fundamenta en su capacidad de segmentación semántica, un avance importante respecto a las metodologías de clasificación de píxeles tradicionales. Los niveles de precisión alcanzados guardan

una estrecha correlación con los resultados de Ramadhani et al. [9], quienes demostraron que la integración de datos de la misión Sentinel-2 es determinante para el mapeo automático de las etapas de crecimiento del arroz debido a su resolución temporal y espectral. Mientras que autores como Saadat et al. [14], proponen el uso de series temporales combinando Sentinel-1 (Radar) y Sentinel-2 (Óptico) para mejorar la identificación en zonas con alta nubosidad, este estudio en particular muestra que, mediante una arquitectura U-Net optimizada, es posible obtener resultados altamente competitivos (IoU de 0,84) utilizando exclusivamente datos multiespectrales.

La elección de la arquitectura U-Net ha sido validada como el estándar para la segmentación de estructuras complejas. Aunque originalmente fue propuesta por Ronneberger et al. [15] para el ámbito biomédico, su capacidad para preservar detalles espaciales mediante conexiones de salto resulta ser una ventaja útil en la teledetección agrícola. Esta característica permitió que el modelo presentara un rendimiento sobresaliente en el área de entrenamiento en Rio Grande do Sul, Brasil, con una exactitud del 96 %, al tiempo que exhibe una notable capacidad de transferencia en pruebas externas realizadas en Panamá y Estados Unidos. Con estos resultados en diversas geografías indica que el modelo ha capturado las firmas espectrales universales de los cultivos de arroz, consolidándose como una solución escalable y de bajo costo para el inventario arrocero internacional.

Para futuras iteraciones de esta investigación, se propone explorar combinaciones de hiperparámetros y mecanismos de atención para cerrar la brecha de precisión frente a soluciones comerciales, manteniendo la soberanía tecnológica y la reducción de costos operativos en la monitorización agrícola regional.

Conclusiones

La presente investigación mostró la alta eficacia de la arquitectura U-Net combinada con el procesamiento de imágenes multiespectrales de la plataforma Sentinel-2 para la identificación automatizada de cultivos de arroz. La implementación de una estrategia de Data Augmentation resultó ser un factor determinante en la optimización del modelo.

Se encontró que el uso de bandas espectrales específicas, particularmente el infrarrojo cercano, junto con las conexiones de salto de la U-Net, permitió una recuperación de la morfología de las parcelas, incluso en condiciones de alta densidad de cultivo donde las firmas espectrales suelen confundirse con el entorno. Se recomienda la integración de mecanismos de atención (*Attention Gates*) y el uso de datos de mayor resolución espacial para mejorar la delimitación de caminerías y bordes críticos identificados como limitaciones actuales.

Contribución y autoría

E.P.: Conceptualización, administración del proyecto, supervisión, curación de datos de la Conab y redacción del borrador original. **G.M.:** Desarrollo del software, implementación de la arquitectura U-Net en entornos de aprendizaje profundo y optimización de hiperparámetros. **S.C.:** Metodología, validación técnica de las métricas de rendimiento (Accuracy, IoU, Dice) y análisis formal del procesamiento de imágenes satelitales Sentinel-2. **R.B.:** Adquisición de recursos, análisis de las pruebas externas en Panamá y Estados Unidos. Todos los autores han leído y aprobado la versión final del manuscrito.

Financiamiento

Esta investigación fue financiada por la Universidad de Carabobo, UC, Facultad de Ingeniería, Venezuela a través del Centro de Procesamiento de Imágenes.

Declaración ética

El presente estudio no involucró experimentos con seres humanos ni animales. Los datos de terreno utilizados para el entrenamiento y validación del modelo fueron obtenidos de fuentes institucionales públicas de la Compañía Nacional de Abastecimiento (CONAB) de Brasil, garantizando el uso legítimo de la información para fines de investigación científica.

Uso de inteligencia artificial

Durante la fase de desarrollo, se utilizaron marcos de trabajo de aprendizaje profundo de código abierto para la implementación de la red neuronal U-Net.

Disponibilidad de datos

El conjunto de datos multiespectrales utilizado en esta investigación proviene del programa Copernicus (Sentinel-2) y es de acceso público. Los datos estadísticos y de cobertura de arroz para el estado de Rio Grande do Sul están disponibles a través del [Portal de Informaciones de la CONAB](#). El código fuente de la arquitectura U-Net y los hiperparámetros de entrenamiento detallados en la Tabla 1 pueden ser solicitados al autor para fines de reproducibilidad científica.

Conflictos de intereses

Los autores declaran no tener ningún conflicto de interés en relación con la publicación de este artículo.

REFERENCIAS

- [1] O. Dubovik et al., «Grand Challenges in Satellite Remote Sensing», *Front. Remote Sens.*, vol. 2, p. 619818, feb. 2021, doi: 10.3389/frsen.2021.619818.
- [2] I. Aneece y P. S. Thenkabail, «New Generation Hyperspectral Sensors DESIS and PRISMA Provide Improved Agricultural Crop Classifications», *photogramm eng remote sensing*, vol. 88, n.º 11, pp. 715-729, nov. 2022, doi: 10.14358/PERS.22-00039R2.
- [3] I. Aneece y P. S. Thenkabail, «Classifying Crop Types Using Two Generations of Hyperspectral Sensors (Hyperion and DESIS) with Machine Learning on the Cloud», *Remote Sensing*, vol. 13, n.º 22, p. 4704, nov. 2021, doi: 10.3390/rs13224704.
- [4] S. Ibrahim y H. Balzter, «Evaluating Flood Damage to Paddy Rice Fields Using PlanetScope and Sentinel-1 Data in North-Western Nigeria: Towards Potential Climate Adaptation Strategies», *Remote Sensing*, vol. 16, n.º 19, p. 3657, sep. 2024, doi: 10.3390/rs16193657.
- [5] M. Billah, A. K. M. S. Islam, W. B. Mamoon, y M. R. Rahman, «Random forest classifications for landuse mapping to assess rapid flood damage using Sentinel-

- 1 and Sentinel-2 data», *Remote Sensing Applications: Society and Environment*, vol. 30, p. 100947, abr. 2023, doi: 10.1016/j.rsase.2023.100947.
- [6] I. Aneece y P. Thenkabail, «Accuracies Achieved in Classifying Five Leading World Crop Types and their Growth Stages Using Optimal Earth Observing-1 Hyperion Hyperspectral Narrowbands on Google Earth Engine», *Remote Sensing*, vol. 10, n.º 12, p. 2027, dic. 2018, doi: 10.3390/rs10122027.
- [7] B. Awad y I. Erer, «FAUNet: Frequency Attention U-Net for Parcel Boundary Delineation in Satellite Images», *Remote Sensing*, vol. 15, n.º 21, p. 5123, oct. 2023, doi: 10.3390/rs15215123.
- [8] J. Han *et al.*, «NESEA-Rice10: high-resolution annual paddy rice maps for Northeast and Southeast Asia from 2017 to 2019», *Earth Syst. Sci. Data*, vol. 13, n.º 12, pp. 5969-5986, dic. 2021, doi: 10.5194/essd-13-5969-2021.
- [9] F. Ramadhani, R. Pullanagari, G. Kereszturi, y J. Procter, «Automatic Mapping of Rice Growth Stages Using the Integration of SENTINEL-2, MOD13Q1, and SENTINEL-1», *Remote Sensing*, vol. 12, n.º 21, p. 3613, nov. 2020, doi: 10.3390/rs12213613.
- [10] Sinergise Solutions d.o.o., a Planet Labs company, «EO Browser». 2026. [En línea]. Disponible en: <https://apps.sentinel-hub.com/eo-browser/>
- [11] Y. Yu, L. Meng, C. Luo, B. Qi, X. Zhang, y H. Liu, «Early Mapping Method for Different Planting Types of Rice Based on Planet and Sentinel-2 Satellite Images», *Agronomy*, vol. 14, n.º 1, p. 137, ene. 2024, doi: 10.3390/agronomy14010137.
- [12] M. Wang, J. Wang, Y. Cui, J. Liu, y L. Chen, «Agricultural Field Boundary Delineation with Satellite Image Segmentation for High-Resolution Crop Mapping: A Case Study of Rice Paddy», *Agronomy*, vol. 12, n.º 10, p. 2342, sep. 2022, doi: 10.3390/agronomy12102342.
- [13] Q. Chen *et al.*, «UAV remote sensing imagery-based semantic segmentation approach for lodged rice region», *Smart Agricultural Technology*, vol. 13, p. 101689, mar. 2026, doi: 10.1016/j.atech.2025.101689.

- [14] M. Saadat, S. T. Seydi, M. Hasanlou, y S. Homayouni, «A Convolutional Neural Network Method for Rice Mapping Using Time-Series of Sentinel-1 and Sentinel-2 Imagery», *Agriculture*, vol. 12, n.º 12, p. 2083, dic. 2022, doi: 10.3390/agriculture12122083.
- [15] O. Ronneberger, P. Fischer, y T. Brox, «U-Net: Convolutional Networks for Biomedical Image Segmentation», 18 de mayo de 2015, *arXiv*: arXiv:1505.04597. doi: 10.48550/arXiv.1505.04597.

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.