

Estimación de la producción del cultivo de arroz mediante imágenes multiespectrales Sentinel-2 a través de una ResNet18

Estimation of rice crop production using Sentinel-2 multispectral images through a ResNet18

Estimativa da produção da cultura do arroz por meio de imagens multiespectrais Sentinel-2 utilizando uma ResNet18

García Teodoro ^{1*}, Seijas César ¹, Roche Daniela ¹, Vargas Cristian ¹

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

✉ tgarcia@uc.edu.ve | ORCID: <https://orcid.org/0000-0001-5028-6818>
✉ cseijas@uc.edu.ve | ORCID: <https://orcid.org/0000-0001-6050-4436>
✉ droche@uc.edu.ve | ORCID: <https://orcid.org/0009-0000-8482-2172>
✉ cvargas2@uc.edu.ve | ORCID: <https://orcid.org/0009-0005-3694-1165>
E-mail de correspondencia: tgarcia@uc.edu.ve

Revista Saastal

Vol. 1(1) enero - junio 2025

<https://doi.org/10.63804/saastal.v1i1.e1>

Como citar este artículo

García Teodoro, G., Seijas, C., Roche, D., & Vargas, C. (2025). *Estimación de la producción del cultivo de arroz mediante imágenes multiespectrales Sentinel-2 a través de una ResNet18*. Saastal, 1(1), e1.

© 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 enero de 2025
Revisado: 10 de febrero de 2025
Aceptado: 25 de febrero de 2025
Publicado: 05 de marzo de 2025

Resumen

La seguridad alimentaria global depende de sistemas de monitoreo agrícola precisos, siendo el arroz uno de los cultivos más críticos. Sin embargo, la estimación de su producción enfrenta desafíos en regiones donde la información parcelaria detallada es escasa. El presente trabajo desarrolla y valida una metodología reproducible para estimar la producción agrícola de arroz en Rio Grande do Sul, Brasil, integrando imágenes multiespectrales de la misión Sentinel-2 y redes neuronales convolucionales profundas (CNN). El flujo de trabajo automatizado implementado abarca la descarga de productos satelitales, el preprocesamiento radiométrico y la segmentación de mosaicos correspondientes a dos etapas fenológicas clave: reproductiva y de maduración. Para el análisis, se adaptó una arquitectura ResNet18, modificando su capa de entrada para procesar 10 canales espectrales y se entrenó utilizando 2.304 parches de 64x64 píxeles. Las etiquetas de entrenamiento se generaron de forma proporcional a los datos de rendimiento oficiales del IBGE y CONAB, permitiendo al modelo aprender la relación entre la respuesta espectral y la productividad real por municipio. El desempeño se evaluó mediante métricas de error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2), alcanzando valores de R^2 próximos a 0,91. Estos resultados reflejan una precisión significativamente superior respecto a los métodos tradicionales basados exclusivamente en índices vegetativos como el NDVI. Se concluye que la metodología es altamente reproducible y escalable, facilitando su aplicación en otras regiones geográficas y tipos de cultivos. Los aportes de esta investigación representan un avance concreto hacia la democratización de la agricultura de precisión mediante el uso de software de código abierto y datos satelitales gratuitos.

Palabras clave: agricultura de precisión, arroz, aprendizaje profundo, cultivos, sensores remotos, vigilancia ambiental.

Abstract

Global food security depends on accurate agricultural monitoring systems, with rice being one of the most critical crops. However, estimating its production faces significant challenges in regions where detailed parcel-level information is scarce. This study develops and validates a reproducible methodology to estimate rice production in Rio Grande do Sul, Brazil, by integrating multispectral imagery from the Sentinel-2 mission and deep convolutional neural networks (CNNs). The implemented automated workflow encompasses the download of satellite products, radiometric preprocessing, and mosaic segmentation corresponding to two key phenological stages: reproductive and maturation. For the analysis, a ResNet18 architecture was adapted by modifying its input layer to process 10 spectral channels, and the model was trained using 2,304 patches of 64×64 pixels. Training labels were generated proportionally to official yield data from IBGE and CONAB, allowing the model to learn the relationship between spectral response and actual productivity at the municipal level. Model performance was evaluated using mean absolute error (MAE), root mean square error (RMSE), and the coefficient of determination (R^2), achieving R^2 values close to 0.91. These results reflect significantly higher accuracy compared with traditional methods based exclusively on vegetation indices such as NDVI. It is concluded that the proposed methodology is highly reproducible and scalable, facilitating its application to other geographical regions and crop types. The contributions of this research represent a concrete advance toward the democratization of precision agriculture through the use of open-source software and freely available satellite data.

Keywords: precision agriculture, rice, deep learning, crops, remote sensing, environmental monitoring.

Resumo

A segurança alimentar global depende de sistemas precisos de monitoramento agrícola, sendo o arroz uma das culturas mais importantes. No entanto, a estimativa de sua produção enfrenta desafios significativos em regiões onde há escassez de informações detalhadas em nível de parcela agrícola. Este estudo desenvolve e valida uma metodologia reproduzível para estimar a produção de arroz no Rio Grande do Sul, Brasil, por meio da integração de imagens multiespectrais da missão Sentinel-2 e redes neurais convulsionais profundas (CNNs). O fluxo de trabalho automatizado implementado abrange o download de produtos de satélite, o pré-processamento radiométrico e a segmentação de mosaicos correspondentes a duas fases fenológicas-chave: reprodutiva e de maturação. Para a análise, uma arquitetura ResNet18 foi adaptada mediante a modificação de sua camada de entrada para processar 10 canais espectrais, e o modelo foi treinado utilizando 2.304 patches de 64×64 pixels. Os rótulos de treinamento foram gerados proporcionalmente aos dados oficiais de produtividade do IBGE e da CONAB, permitindo que o modelo aprendesse a relação entre a resposta espectral e a produtividade real em nível municipal. O desempenho do modelo foi avaliado por meio do erro absoluto médio (MAE), da raiz do erro quadrático médio (RMSE) e do coeficiente de determinação (R^2), alcançando valores de R^2 próximos de 0,91. Esses resultados refletem uma precisão significativamente superior em comparação com métodos tradicionais baseados exclusivamente em índices de vegetação, como o NDVI. Conclui-se que a metodologia proposta é altamente reproduzível e escalável, facilitando sua aplicação em outras regiões geográficas e tipos de culturas agrícolas. As contribuições desta pesquisa representam um avanço concreto rumo à democratização da agricultura de precisão por meio do uso de software de código aberto e de dados de satélite de livre acesso.

Palavras-chave: agricultura de precisão, arroz, aprendizado profundo, culturas agrícolas, sensoriamento remoto, monitoramento ambiental.

Introducción

La producción sostenible de alimentos es un reto global agravado por el incremento poblacional y las limitaciones de recursos. El arroz, como cereal base en muchas regiones, exige sistemas de manejo eficientes para satisfacer una demanda estimada al alza para 2050 [1]. La agricultura de precisión adopta tecnologías de información para gestionar la variabilidad espacial y temporal de los cultivos, con la teledetección como eje central. Satélites como Sentinel-2 proporcionan imágenes multiespectrales a resoluciones de hasta 10 metros [2], facilitando el monitoreo sistemático y la toma de decisiones agronómicas informadas.

La misión Sentinel-2, parte del programa Copernicus, ha revolucionado el monitoreo terrestre al ofrecer una combinación única de alta resolución espacial y una frecuencia de revisión de cinco días, lo cual es crítico para capturar las rápidas transiciones en las etapas fenológicas del arroz. No obstante, el procesamiento de este volumen de datos multiespectrales requiere de herramientas capaces de interpretar patrones no lineales que los índices tradicionales suelen omitir [3]. En este sentido, la arquitectura ResNet18 se presenta como una solución óptima; su diseño basado en el aprendizaje de residuos permite entrenar redes profundas evitando la degradación del gradiente, lo que facilita la extracción de características complejas incluso en datasets de tamaño moderado. Al adaptar esta red para procesar múltiples canales de información satelital, se logra una sinergia que potencia la capacidad predictiva sobre el rendimiento agrícola en regiones con alta variabilidad climática [4], [5].

En este escenario, la integración de datos satelitales y modelos de aprendizaje profundo emerge como una solución viable para superar las barreras de información [6], permitiendo inferir indicadores clave a partir de la interpretación de patrones espectrales y temporales. El avance en redes convolucionales, especialmente la familia ResNet [7], facilita la explotación de representaciones complejas a partir de imágenes multicanal.

A partir de lo expuesto, el presente trabajo tuvo como objetivo desarrollar y validar una metodología reproducible basada en aprendizaje profundo para la estimación de la producción agrícola de arroz en Rio Grande do Sul, Brasil. A través de la integración de series temporales multiespectrales de Sentinel-2 y una arquitectura ResNet18 adaptada para procesar múltiples canales de información, se busca alcanzar altos niveles de precisión en la predicción de rendimientos y proponer un flujo de trabajo automatizado que supere las limitaciones críticas impuestas por la escasez de datos parcelarios locales. Con este abordaje, se pretende fortalecer las herramientas de monitoreo en la agricultura de precisión y

proporcionar un modelo de referencia escalable que pueda ser adaptado a otros cultivos estratégicos en contextos latinoamericanos, donde el acceso a catastros agrícolas digitalizados es frecuentemente limitado.

Metodología

Área de estudio y fuentes de datos

El estudio se centró en el estado de Rio Grande do Sul, Brasil, región líder en la producción de arroz irrigado. Para garantizar la fiabilidad del modelo, se utilizaron las siguientes fuentes de datos oficiales:

- Datos estadísticos: las series históricas de superficie cosechada y rendimiento agrícola a nivel municipal se obtuvieron del Sistema IBGE de Recuperación Automática (SIDRA-IBGE) y de la Compañía Nacional de Abastecimiento (CONAB) [8], [9].
- Datos geoespaciales: los límites administrativos municipales se obtuvieron en formato vectorial (Shapefile) a través de la Agencia Nacional de Aguas y Saneamiento Básico (ANA) y el Ministerio de Agricultura (MAPA) [10], procesados para asegurar la delimitación espacial precisa de las zonas de cultivo (Fig. 1).
- Datos satelitales: se emplearon imágenes multiespectrales de la misión Sentinel-2 (Nivel-2A, reflectancia en el fondo de la atmósfera - BOA), obtenidas a través del servicio Copernicus.2.2.

Implementación de software y entorno computacional

El procesamiento de datos y el desarrollo de la arquitectura de aprendizaje profundo se realizaron bajo la siguiente configuración técnica:

- Lenguaje de programación: Python v.3.10 (Python Software Foundation), seleccionado por su robustez en el manejo de librerías geoespaciales y tensores.
- Entorno de Deep Learning: PyTorch v.2.0.1 (Meta AI) para la construcción y entrenamiento de la red convolucional. PyTorch Lightning v.2.0 para la automatización y escalabilidad del flujo de entrenamiento.
- Procesamiento geoespacial: Rasterio v.1.3.0 y Geopandas v.0.12.0 para la manipulación de mosaicos satelitales y segmentación de parches. QGIS v.3.28 Firenze (QGIS Development Team) para la validación visual de los límites administrativos y generación de cartografía temática.

- Análisis Estadístico: Scikit-learn v.1.2.2 para el cálculo de las métricas de desempeño (MAE, RMSE y R^2).



Figura 1. Mapa de Rio Grande do Sul con zonas arroceras.

Procesamiento de imágenes satelitales y preparación del Dataset

El flujo de preprocesamiento se diseñó para capturar la firma espectral del cultivo en sus momentos críticos de desarrollo. El procedimiento se estructuró de la siguiente manera:

- Adquisición de datos: se utilizaron imágenes de la misión Sentinel-2 (L2A) capturadas entre 2017 y 2022. Se aplicó un filtro de calidad para descartar escenas con una cobertura de nubes superior al 20 %, asegurando la integridad de los datos espectrales.
- Selección de bandas y ventanas fenológicas: se seleccionaron las bandas correspondientes al espectro visible (RGB) e Infrarrojo Cercano (NIR), además del cálculo del Índice de Vegetación de Diferencia Normalizada (NDVI). Estos datos se extrajeron para dos ventanas temporales críticas: la etapa reproductiva y la etapa de maduración, periodos donde la respuesta espectral guarda la mayor correlación con el rendimiento final.
- Segmentación y extracción (Pipeline): utilizando la API de Google Earth Engine (GEE) y scripts personalizados en Python, se enmascararon las áreas de cultivo de arroz dentro de los límites de cada municipio. Posteriormente, las imágenes resultantes se segmentaron en parches de 64×64 píxeles, generando un dataset de 2,304 muestras preparadas para la entrada en la red neuronal (Fig. 2).



Figura 2. Ejemplo de mosaico Sentinel-2 con máscara municipal.

Arquitectura del modelo y entrenamiento

Para la estimación de la producción, se implementó una variante de la red ResNet18, ajustada bajo los siguientes hiperparámetros y criterios técnicos:

- Adaptación de la capa de entrada: la arquitectura original (diseñada para 3 canales RGB) fue modificada para procesar una entrada multiespectral de 10 canales, integrando la información de las dos ventanas fenológicas y los índices calculados.
- Función de pérdida (Loss Function): se utilizó la función de pérdida Huber Loss, seleccionada por su robustez frente a valores atípicos (outliers) en los datos de rendimiento municipal, combinando las ventajas del Error Cuadrático Medio (MSE) y el Error Absoluto Medio (MAE).

- Optimización: se empleó el optimizador Adam con una tasa de aprendizaje (learning rate) inicial de 10^{-4} , ajustada mediante un programador de reducción de tasa de aprendizaje tras el estancamiento de la pérdida en el conjunto de validación.
- Configuración del entrenamiento: el modelo se entrenó durante 100 épocas con un tamaño de lote (batch size) de 32, utilizando una división de datos de 80 % para entrenamiento y 20 % para validación externa. Se implementó la técnica de Early Stopping para prevenir el sobreajuste (overfitting).

Construcción y normalización del Dataset

Dada la ausencia de datos parcelarios de alta resolución, se implementó un método de desagregación espacial para la generación de etiquetas. El proceso se rigió por los siguientes criterios técnicos:

- Validación de presencia del cultivo: cada parche de 64×64 píxeles fue sometido a una máscara de clasificación previa. Solo se incluyeron en el dataset aquellos fragmentos que presentaran un mínimo del 15 % de píxeles identificados como arroz, asegurando que la señal espectral fuera representativa del cultivo (Tabla 1).
- Estimación de la producción (Labeling), $Prod_{parche}$: la etiqueta de producción se calculó mediante una distribución proporcional. Se tomó el rendimiento oficial municipal (R_m) y se ajustó según la superficie activa de arroz identificada dentro de cada parche (S_p), asumiendo una distribución uniforme del rendimiento dentro de las áreas cultivadas del municipio, Ecuación 1:

$$Prod_{parche} = R_m \times S_p \quad \text{Ecuación 1}$$

- Gestión de metadatos: se estructuró un inventario en formato CSV integrando el identificador del fragmento (*filename*), la producción calculada (*prod*) y la fracción de la región de interés ocupada por el cultivo (*roi_fraction*).

Tabla 1. Estructura del Dataset y valores calculados por parche.

filename	prod (label)	roi_fraction
2324_4321600_4_12.tif	151923.38	50.927734375
1920_4307708_2_3.tif	271390.0	94.6533203125
1920_4312443_10_6.tif	89744.34	33.2275390625
1920_4321204_13_4.tif	45349.12	24.365234375

filename	prod (label)	roi_fraction
2223_4312443_5_7.tif	63220.000000000001	21.2890625
1920_4306908_8_9.tif	66780.0	23.291015625

Estrategias de normalización

Para garantizar la estabilidad numérica durante el descenso de gradiente y evitar la explosión de gradientes debida a las magnitudes de la producción (en kg), se evaluaron dos técnicas de escalado sobre las etiquetas (Tabla 2):

1. MinMaxScaler (mm): transforma los datos al rango [0, 1], definida por la Ecuación 2:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad \text{Ecuación 2}$$

2. StandardScaler (z): estandariza las etiquetas para que tengan una media (μ) de 0 y una desviación estándar (σ) de 1, facilitando la convergencia en modelos basados en redes residuales [11].

Tabla 2. Comparativa de valores de producción normalizados para el entrenamiento.

filename	prod	norm_mm	norm_z
2223_4302402_0_0.tif	15919.2	0.0226564113002893	-1.7196216166563882
2223_4302402_0_1.tif	22286.88	0.0411732992133998	-1.642280858643287
1920_4322533_6_0.tif	191304.0	0.5326664437239192	0.4105723277591793
1920_4322533_7_0.tif	96552.0	0.257132471611149	-0.7402693450725819

Arquitectura del modelo y entrenamiento

Arquitectura del Modelo y Entrenamiento

El núcleo computacional de esta investigación se basa en la arquitectura ResNet18, seleccionada por su eficacia en la mitigación del desvanecimiento del gradiente mediante el uso de conexiones residuales. Como se detalla en la Figura 3, el diseño estándar está optimizado para imágenes de tres canales (RGB) y tareas de clasificación con múltiples salidas.




Figura 3. Esquema de la arquitectura ResNet18 convencional, resaltando la entrada de 3 canales y la capa de salida para clasificación de 1000 categorías.

Para los propósitos de este estudio, se realizó una reingeniería del modelo original para adaptarlo a un problema de regresión multispectral. Esta modificación, ilustrada en la Figura 4, incluyó la implementación de una capa convolucional inicial de 1×1 diseñada para reducir la dimensionalidad de la entrada de 10 canales a 3, permitiendo así aprovechar los pesos pre-entrenados de los bloques residuales subsiguientes. Asimismo, la capa final de clasificación fue sustituida por una capa densamente conectada (fully connected) con una única salida lineal para la predicción continua de la producción de arroz.




Figura 4. Arquitectura ResNet18 adaptada: se detalla la adición de la capa convolucional 1×1 para el procesamiento de 10 bandas espectrales y la transición a una salida de regresión única para la estimación de producción.

El flujo de entrenamiento se gestionó mediante PyTorch Lightning [12], integrando técnicas de aceleración por GPU y un sistema de early stopping para optimizar la convergencia y evitar el sobreajuste. El modelo fue entrenado utilizando el optimizador Adam y la función de pérdida Huber Loss, evaluando el desempeño en una partición del 5 % de datos totalmente independientes del proceso de ajuste.

Evaluación, control de sesgo y reproducibilidad

Para garantizar la integridad científica y la replicabilidad de los experimentos, se implementó un protocolo de control estricto basado en las siguientes directrices:

- Entorno de ejecución: todos los procesos de preprocesamiento, entrenamiento y evaluación fueron automatizados mediante scripts desarrollados en Python v.3.10, ejecutados en el entorno Google Colab Pro. Se utilizaron unidades de procesamiento gráfico (GPU NVIDIA Tesla T4) para asegurar la consistencia en los tiempos de cómputo y la gestión de tensores.
- Gestión de la aleatoriedad: se fijaron semillas aleatorias (seeds) específicas para todas las librerías involucradas (NumPy, PyTorch y Random), asegurando que la partición

del dataset y la inicialización de los pesos de la red sean idénticas en ejecuciones sucesivas.

- Control de metadatos: se implementó un sistema de logging automático para almacenar los metadatos de cada muestreo, permitiendo la trazabilidad completa desde la descarga de la imagen satelital hasta el valor de predicción final.
- Métricas de desempeño: además del R^2 , se calcularon el Error Absoluto Medio (MAE) y la Raíz del Error Cuadrático Medio (RMSE) para penalizar de forma diferenciada los errores de gran magnitud, proporcionando una visión multidimensional de la robustez del modelo.

Resultados y discusión

Calidad del dataset y eficiencia del procesamiento

La metodología implementada permitió la consolidación de un dataset robusto compuesto por 2.304 parches multiespectrales y multitemporales. El filtrado basado en criterios fenológicos y espaciales garantizó que cada muestra fuera representativa de las dinámicas críticas del cultivo de arroz. La automatización integral del flujo de trabajo, desde la ingesta de datos de Sentinel-2 hasta la segmentación, eliminó la subjetividad de la intervención manual, asegurando la integridad de los tensores de entrada para la red neuronal.

Análisis del desempeño del modelo

El modelo ResNet18 adaptado demostró una alta capacidad predictiva, alcanzando un coeficiente de determinación R^2 de 0,91 (± 0.03) en el conjunto de validación. El Error Absoluto Medio (MAE) se situó en un promedio de 15,000 kg/parche, lo que representa un error porcentual relativo del 12 %.

Como se ilustra en la Figura 5, la curva de aprendizaje muestra una convergencia estable, donde la pérdida de validación sigue de cerca a la de entrenamiento, descartando signos de sobreajuste (overfitting).




Figura 5. Evolución de la función de pérdida (Huber Loss) durante las épocas de entrenamiento y validación, evidenciando estabilidad numérica y eficiencia en el aprendizaje residual.

Por su parte, la Figura 6 presenta el diagrama de dispersión entre los valores observados y las predicciones del modelo. Se observa que el modelo exhibe su mayor precisión en los rangos medios de producción; sin embargo, los valores extremos muestran una dispersión ligeramente superior, fenómeno atribuido a la menor densidad de muestras en las colas de la distribución del dataset original.




Figura 6. Gráfico de dispersión que compara la producción observada (IBGE/CONAB) frente a la producción estimada por la ResNet18. La línea de identidad (1:1) resalta la alta linealidad lograda en el conjunto de prueba.

Análisis del desempeño del Modelo

El modelo ResNet18 adaptado demostró una alta capacidad predictiva, alcanzando un coeficiente de determinación R^2 de 0,91 ($\pm 0,03$) en el conjunto de validación. El Error Absoluto Medio (MAE) se situó en un promedio de 15.000 kg/parche, lo que representa un error porcentual relativo del 12 %.

Estabilidad y sensibilidad a la normalización

La Tabla 3 resume los experimentos realizados bajo distintas configuraciones de normalización y semillas aleatorias. Los resultados indican que la normalización Z-Score (norm z) superó consistentemente al escalado Min-Max, alcanzando el pico de desempeño con un R^2 de 0,9411 (Semilla 19).

Tabla 3. Comparativa de resultados según configuración de normalización y variabilidad de semilla.

Configuración	Mejor época	R^2 Score	MAE	% Error	R^2 Ajustado
norm mm, seed 19	15	0,9294	16896,71	13,05	0,9215
norm mm seed 37	6/7	0,9225	17642,98	13,47	0,9138
norm mm, seed 42	14	0,9104	18805,85	13,88	0,9003
norm z, seed 19	7	0,9411	15194,23	11,29	0,9344
norm z, seed 37	6	0,9293	17460,28	13,02	0,9214
norm z, seed 42	8	0,9012	18984,58	12,94	0,8901

Comparación con métodos tradicionales

El modelo propuesto demostró una superioridad significativa frente a las metodologías convencionales basadas únicamente en el Índice de Vegetación de Diferencia Normalizada (NDVI) y regresiones lineales simples. Como se detalla en la Tabla 4, la arquitectura ResNet18 modificada mejora la precisión absoluta (R^2), al tiempo que exhibe una mayor capacidad de generalización ante muestras no vistas, superando incluso a modelos robustos de aprendizaje automático como Random Forest (RF) alimentado con índices multispectrales.

Tabla 4. Comparativa de métricas de desempeño entre modelos basados en índices tradicionales y la arquitectura propuesta [7].

Modelo	R ²	MAE (kg/ha)	RMSE (kg/ha)	% Error
NDVI + Reg. lineal	0,65	22.000	32.500	18
Índices multiespectrales + RF	0,79	11.500	15.100	10
ResNet18 mod. multicanal	0,91	15.000	19.000	12

El coeficiente de determinación alcanzado ($R^2 \approx 0,91$) demuestra que la arquitectura ResNet18 modificada logra capturar dependencias espaciales complejas que los índices de vegetación tradicionales, como el NDVI, suelen simplificar. Mientras que los modelos de regresión lineal basados en índices espectrales tienden a saturarse en etapas de máximo desarrollo foliar, la capacidad multicanal de esta red neuronal permite extraer características latentes en las bandas del infrarrojo cercano y el borde rojo de Sentinel-2 [13].

No obstante, la dispersión observada en los valores extremos de producción sugiere que el modelo aún enfrenta retos ante la heterogeneidad intra-parcelaria. Este fenómeno coincide con resultados en la literatura donde la ausencia de datos parcelarios exactos obliga a asumir una uniformidad que no siempre se cumple en el terreno [14]. Comparado con estudios previos en Latinoamérica que utilizan Random Forest, el uso de aprendizaje profundo en este trabajo reduce el error porcentual promedio al 12 %, fortaleciendo la eficacia de las redes convolucionales para el monitoreo agrícola regional [15].

El abordaje metodológico permitió suplir la limitación de información parcelaria tradicional, validando la capacidad de las redes neuronales convolucionales (CNN) para inferir patrones a partir de datos agregados y agentes espectrales bien contruidos. La integración de múltiples etapas fenológicas resultó ser el factor determinante para mejorar la sensibilidad del modelo. Sin embargo, se identifican las siguientes limitaciones:

- Dependencia de la calidad y resolución de los datos municipales.
- Supuesto de uniformidad espacial del rendimiento, necesario ante la ausencia de datos parcelares.
- Dificultad para modelar valores extremos y zonas con alta heterogeneidad interna.

Se recomienda explorar la integración de información de datos climáticos, así como arquitecturas de redes profundas especializadas en integración multimodal.

Conclusiones

Se logró estimar la producción de arroz a escala por parches de parcelas en Brasil mediante la combinación de imágenes Sentinel-2 y una red ResNet18 adaptada, alcanzando métricas de alta precisión validadas frente a datos oficiales.

La estrategia adoptada es replicable, fácilmente automatizable y adaptable para otras regiones y cultivos, constituyendo un modelo de referencia para investigación y monitoreo en contextos con limitaciones de información local.

El aporte metodológico impulsa la convergencia entre teledetección e inteligencia artificial y fortalece la agricultura de precisión en Latinoamérica.

Contribución y autoría

GTG: conceptualización, redacción del manuscrito original y procesamiento del dataset en Python. **CS:** Adaptación de la arquitectura ResNet18 y supervisión del entrenamiento en PyTorch Lightning. **RD:** Análisis estadístico de resultados (MAE, RMSE, R^2) y validación cruzada. **VC:** Obtención de límites administrativos GIS, segmentación de parches y revisión editorial final.

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

Los autores declaran que el presente estudio se ha llevado a cabo siguiendo los principios éticos de integridad en la investigación científica. Al tratarse de una investigación basada en el procesamiento de imágenes satelitales de acceso abierto (Sentinel-2) y datos estadísticos de fuentes oficiales públicas (IBGE y CONAB), el estudio no involucró la experimentación con seres humanos ni animales, lo cual garantizó el cumplimiento de las normativas de protección de datos y propiedad intelectual.

Uso de inteligencia artificial

Los autores declaran que no se utilizaron herramientas de inteligencia artificial generativa ni tecnologías asistidas por IA en la preparación o redacción de este manuscrito. Todo el contenido, incluida la redacción, el análisis y la presentación de los resultados, fue producido de forma autónoma por los autores.

Disponibilidad de datos

Los datos utilizados en esta investigación están disponibles a través del autor de correspondencia, previa solicitud razonable.

Conflictos de intereses

Los autores manifiestan que no existen conflictos de intereses de índole financiera, personal o profesional que pudieran haber influido en los resultados o interpretaciones presentados en este artículo. La investigación fue financiada íntegramente por las instituciones de adscripción de los autores.

Referencias

- [1] M. C. Rebolledo-Cid *et al.*, «Modelación del arroz en Latinoamérica: Estado del arte y base de datos para parametrización», Publications Office of the European Union, Luxembourg, EUR 29026 ES, 2018. doi: 10.2760/18081.
- [2] S. K. Phang, T. H. A. Chiang, A. Happonen, y M. M. L. Chang, «From Satellite to UAV-Based Remote Sensing: A Review on Precision Agriculture», *IEEE Access*, vol. 11, pp. 127057-127076, 2023, doi: 10.1109/ACCESS.2023.3330886.
- [3] E. Amin *et al.*, «Multi-Season Phenology Mapping of Nile Delta Croplands Using Time Series of Sentinel-2 and Landsat 8 Green LAI», *Remote Sensing*, vol. 14, n.º 8, p. 1812, abr. 2022, doi: 10.3390/rs14081812.
- [4] D. Radha y S. Prasanna, «A unique ADAGRAD optimized DCNN with RESNET-18 Architecture for Indoor Agriculture-Based Crop Yield», en *2024 IEEE International Conference on Computing, Power and Communication Technologies (IC2PCT)*, Greater Noida, India: IEEE, feb. 2024, pp. 767-771. doi: 10.1109/IC2PCT60090.2024.10486749.
- [5] Md. M. Islam *et al.*, «DeepCrop: Deep learning-based crop disease prediction with web application», *Journal of Agriculture and Food Research*, vol. 14, p. 100764, dic. 2023, doi: 10.1016/j.jafr.2023.100764.
- [6] J. A. Quille-Mamani, L. A. Ruiz, J. P. Carbonell-Rivera, y L. Ramos-Fernández, «Predicción del rendimiento del cultivo de arroz mediante imágenes Sentinel-2 y el algoritmo Random Forest», en *Teledetección y Cambio Global: Retos y Oportunidades para un Crecimiento Azul*, Cádiz, 2024, pp. 365-368. [En línea]. Disponible en: https://cgat.webs.upv.es/wp-content/uploads/2024/06/Quille_XX_AET.pdf

- [7] K. He, X. Zhang, S. Ren, y J. Sun, «Deep Residual Learning for Image Recognition», en *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 770-778. doi: 10.1109/CVPR.2016.90.
- [8] Instituto Brasileiro de Geografia e Estatística (IBGE), «SIDRA: Sistema IBGE de Recuperação Automática». [En línea]. Disponible en: <https://sidra.ibge.gov.br>
- [9] Companhia Nacional de Abastecimento (CONAB), «Acompanhamento da Safra Brasileira: Grãos». [En línea]. Disponible en: <https://www.conab.gov.br/info-agro/safras/graos>
- [10] Agência Nacional de Águas e Saneamento Básico (ANA) and Ministério da Agricultura, Pecuária e Abastecimento (MAPA), «Atlas do uso da água na agricultura irrigada no Brasil - 2ª edição», ANA, Brasília, 2021. [En línea]. Disponible en: https://www.snirh.gov.br/portal/centrais-de-conteudos/central-de-publicacoes/atlas-riego-2aedicion/@@download/file/Atlas_Riego.pdf
- [11] F. Pedregosa *et al.*, «Scikit-learn: Machine Learning in Python», *Journal of Machine Learning Research*, vol. 12, pp. 2825-2830, 2011.
- [12] W. Falcon y Others, «PyTorch Lightning». 2019. [En línea]. Disponible en: <https://github.com/Lightning-AI/lightning>
- [13] S. Wang *et al.*, «Mapping Crop Types in Southeast India with Smartphone Crowdsourcing and Deep Learning», *Remote Sensing*, vol. 12, n.º 18, p. 2957, sep. 2020, doi: 10.3390/rs12182957.
- [14] A. Barriguiha, M. De Castro Neto, y A. Gil, «Vineyard Yield Estimation, Prediction, and Forecasting: A Systematic Literature Review», *Agronomy*, vol. 11, n.º 9, p. 1789, sep. 2021, doi: 10.3390/agronomy11091789.
- [15] H. Burdett y C. Wellen, «Statistical and machine learning methods for crop yield prediction in the context of precision agriculture», *Precision Agric*, vol. 23, n.º 5, pp. 1553-1574, oct. 2022, doi: 10.1007/s11119-022-09897-0.

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.