

# Clasificación fenológica de cultivos de arroz usando ResNet-18 e imágenes Sentinel-2

Phenological classification of rice crops using ResNet-18 and Sentinel-2 images

Classificação fenológica da cultura do arroz por meio de imagens Sentinel-2 e da rede neural ResNet-18

Villazana Sergio <sup>1\*</sup>, Seijas César <sup>1</sup>, Pérez Egilda <sup>1</sup>

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

✉ [svillaza@uc.edu.ve](mailto:svillaza@uc.edu.ve) | ORCID: <https://orcid.org/0000-0002-4495-1479>

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

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

E-mail de correspondencia: [svillaza@uc.edu.ve](mailto:svillaza@uc.edu.ve)

Revista Saastal

Vol. 1(1) enero - junio 2025

## Como citar este artículo

Villazana, S., Seijas, C., & Pérez, E. (2025). *Clasificación fenológica de cultivos de arroz usando ResNet-18 e imágenes Sentinel-2*. Saastal, 1(1), e2.

© 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: 22 de enero de 2025  
Revisado: 18 de febrero de 2025  
Aceptado: 05 de marzo de 2025  
Publicado: 20 de marzo de 2025

## Resumen

La clasificación de los estados fenológicos del arroz es un factor crítico para la seguridad alimentaria, puesto que permite optimizar el uso de fertilizantes, el riego y la planificación de la cosecha. Sin embargo, el monitoreo tradicional en campo es costoso y difícil de escalar. Este estudio propone un método avanzado de teledetección basado en la arquitectura de red neuronal residual ResNet-18 e imágenes satelitales Sentinel-2 para identificar automáticamente las etapas vegetativas, reproductiva y de maduración. La investigación se centró en seis municipios del estado de Rio Grande do Sul, Brasil, durante los ciclos agrícolas 2019-2020, 2022-2023 y 2023-2024. Metodológicamente, la red fue adaptada para procesar parches de 64×64 píxeles, utilizando una configuración innovadora de cinco canales de entrada compuestos por índices de vegetación específicos (NDVI, GNDVI, EVI, NDRE y SAVI), en lugar de bandas espectrales convencionales. Esta integración permitió capturar firmas biofísicas robustas frente a variaciones atmosféricas. Los resultados encontrados en el conjunto de prueba independiente mostraron un desempeño sobresaliente, con una exactitud del 92,17 %, precisión del 92,22 %, sensibilidad (recall) del 92,23 % y un F1-score del 92,15 %. Además, el índice Kappa de 88,26 % confirma una alta concordancia y estabilidad del modelo frente al azar. Se concluye que la combinación de aprendizaje profundo con índices de vegetación multispectrales proporciona una herramienta escalable y altamente confiable para el monitoreo agrícola de precisión. El modelo demostró ser resiliente incluso en escenarios con disponibilidad limitada de datos por nubosidad, lo que facilita su implementación en regiones tropicales y subtropicales para la toma de decisiones basada en datos en tiempo real.

**Palabras clave:** agricultura de precisión; aprendizaje profundo; índices de vegetación; monitoreo fenológico; teledetección multispectral.

## Abstract

The classification of rice phenological stages is a critical factor for food security, as it enables the optimization of fertilizer use, irrigation management, and harvest planning. However, traditional field monitoring is costly and difficult to scale. This study proposes an advanced remote sensing method based on the ResNet-18 residual neural network architecture and Sentinel-2 satellite imagery to automatically identify vegetative, reproductive, and maturation stages. The research focused on six municipalities in the state of Rio Grande do Sul, Brazil, during the 2019-2020, 2022-2023, and 2023-2024 agricultural cycles. Methodologically, the network was adapted to process  $64 \times 64$ -pixel patches, employing an innovative five-channel input configuration composed of specific vegetation indices (NDVI, GNDVI, EVI, NDRE, and SAVI) instead of conventional spectral bands. This integration enabled the capture of robust biophysical signatures under varying atmospheric conditions. Results obtained from the independent test set demonstrated outstanding performance, with an accuracy of 92.17 %, precision of 92.22 %, recall (sensitivity) of 92.23 %, and an F1-score of 92.15 %. Furthermore, a Kappa index of 88.26 % confirms high agreement and model stability beyond chance. It is concluded that the combination of deep learning and multispectral vegetation indices provides a scalable and highly reliable tool for precision agricultural monitoring. The model proved resilient even in scenarios with limited data availability due to cloud cover, facilitating its implementation in tropical and subtropical regions for real-time data-driven decision-making.

**Keywords:** precision agriculture; deep learning; vegetation indices; phenological monitoring; multispectral remote sensing.

## Resumo

A classificação dos estágios fenológicos do arroz é um fator crítico para a segurança alimentar, pois permite otimizar o uso de fertilizantes, o manejo da irrigação e o planejamento da colheita. No entanto, o monitoramento tradicional em campo é oneroso e difícil de escalar. Este estudo propõe um método avançado de sensoriamento remoto baseado na arquitetura de rede neural residual ResNet-18 e em imagens de satélite Sentinel-2 para identificar automaticamente os estágios vegetativo, reprodutivo e de maturação. A pesquisa concentrou-se em seis municípios do estado do Rio Grande do Sul, Brasil, durante os ciclos agrícolas de 2019-2020, 2022-2023 e 2023-2024. Metodologicamente, a rede foi adaptada para processar patches de  $64 \times 64$  pixels, empregando uma configuração inovadora de entrada composta por cinco canais específicos de índices de vegetação (NDVI, GNDVI, EVI, NDRE e SAVI), em substituição às bandas espectrais convencionais. Essa integração permitiu capturar assinaturas biofísicas robustas sob diferentes condições atmosféricas. Os resultados obtidos no conjunto de teste independente demonstraram desempenho excepcional, com acurácia de 92,17 %, precisão de 92,22 %, revocação (sensibilidade) de 92,23 % e escore F1 de 92,15 %. Além disso, um índice Kappa de 88,26 % confirma a elevada concordância e estabilidade do modelo além do acaso. Conclui-se que a combinação de aprendizado profundo e índices de vegetação multiespectrais fornece uma ferramenta escalável e altamente confiável para o monitoramento agrícola de precisão. O modelo mostrou-se resiliente mesmo em cenários com disponibilidade limitada de dados devido à cobertura de nuvens, facilitando sua implementação em regiões tropicais e subtropicais para a tomada de decisões em tempo real baseada em dados.

**Palavras-chave:** agricultura de precisão; aprendizado profundo; índices de vegetação; monitoramento fenológico; sensoriamento remoto multiespectral.

## Introducción

El arroz (*Oryza sativa*) representa el pilar fundamental de la seguridad alimentaria global, sustentando a más de la mitad de la población mundial y representando una fuente importante de calorías en economías emergentes [1], [2]. No obstante, la sostenibilidad de su producción se encuentra bajo la presión constante de la variabilidad climática, el estrés hídrico y la necesidad urgente de reducir las emisiones de gases de efecto invernadero asociadas al cultivo inundado [3]. En este escenario, el monitoreo preciso de las etapas fenológicas más que una tarea técnica, es una necesidad estratégica para optimizar la aplicación de fertilizantes, gestionar el riego de precisión y predecir los rendimientos con exactitud antes de la cosecha [4].

Tradicionalmente, la caracterización fenológica se ha basado en inspecciones *in situ*, métodos que, aunque precisos a escala de parcela, resultan inviables para el monitoreo a gran escala debido a sus elevados costos operativos y su limitada cobertura espacio-temporal [5]. Como alternativa, la teledetección satelital ha replanteado la agronomía digital puesto que permite el mapeo en tiempo casi real. Sensores como Sentinel-2, de la Agencia Espacial Europea, han transformado esta disciplina gracias a su alta resolución temporal (5 días) y espacial (10 m), facilitando la derivación de Índices de Vegetación (IV) que capturan la dinámica espectral del cultivo [6].

La literatura científica ha documentado extensamente el uso de IV como el Índice de Vegetación de Diferencia Normalizada (NDVI), el Índice de Vegetación Ajustado al Suelo (SAVI) y el Índice de Borde Rojo (NDRE) para discriminar fases que van desde el trasplante hasta la maduración senescente [2]. Sin embargo, estos enfoques basados en umbrales fijos enfrentan desafíos importantes: la saturación de la señal en etapas de máxima biomasa, interferencia del ruido de fondo del suelo y la sensibilidad a las condiciones atmosféricas. Si bien la integración de sensores como Sentinel-1 ha mitigado parcialmente la problemática asociados con la nubosidad, armonización de resoluciones y la complejidad del procesamiento de datos siguen siendo barreras significativas para la automatización global [7].

En los últimos años, el Aprendizaje Profundo (*Deep Learning*) ha surgido como el paradigma dominante para superar las limitaciones de los métodos paramétricos tradicionales [8]. A diferencia de los modelos basados exclusivamente en IV, las Redes Neuronales Convolucionales (CNN) tienen la capacidad intrínseca de extraer características jerárquicas espaciales y espectrales de manera simultánea [9]. Sin embargo, la aplicación de arquitecturas


robustas para la clasificación fenológica multiclase en series temporales de Sentinel-2 aún requiere una validación que garantice la precisión frente a la variabilidad fenotípica de los cultivos [10].

El presente artículo propone el desarrollo y evaluación de un modelo basado en la arquitectura ResNet-18 para la clasificación fenológica automática de cultivos de arroz. Utilizando imágenes Sentinel-2 armonizadas y remuestreadas a 10 metros de resolución, se analiza la capacidad de la red para distinguir entre etapas vegetativas, reproductivas y de maduración. El estudio busca demostrar que la integración de la profundidad de ResNet-18 con datos multiespectrales podría superar la precisión de los enfoques basados en umbrales de IV al tiempo que proporciona una herramienta de agricultura de precisión escalable y altamente automatizada.

## Metodología

### *Área de estudio y contexto geográfico*

La investigación se desarrolló en el estado de Rio Grande do Sul, Brasil, una región estratégica para la seguridad alimentaria del Cono Sur. Se seleccionaron seis municipios productores representativos, analizados en tres ciclos agrícolas distintos para capturar la variabilidad interanual: 2019-2020 (Taquara y Vale Do Sol), 2022-2023 (Torres y São João Do Polêsine) y 2023-2024 (Mampituba y Morrinhos Do Sul). El área total bajo monitoreo directo ascendió a 3.094,5 ha, integradas en una base regional más amplia que abarca hasta 17.616,9 ha sembradas en el último periodo. Geográficamente, el estudio se delimita entre las latitudes 29,2° y 29,8° S, y las longitudes 49,5° y 53,5° O (Figura 1).



**Figura 1.** Localización geográfica del área de estudio. Distribución espacial de las fincas arroceras y delimitación administrativa de los municipios seleccionados en el estado de Rio Grande do Sul, Brasil.

### *Materiales y software*

Para garantizar la reproducibilidad científica, se detallan los recursos tecnológicos empleados:

- Datos geoespaciales. Poligonales vectoriales de la Compañía Nacional de Abastecimiento (CONAB) de Brasil [11].
- Sensores remotos. Imágenes multiespectrales de la constelación Sentinel-2 (Level-2A, reflectancia de superficie).
- Plataformas de procesamiento. Google Earth Engine (GEE) para la extracción masiva de datos y Google Colab (entorno basado en la nube con aceleración por GPU NVIDIA Tesla T4) para el entrenamiento del modelo.
- Ecosistema de software. Python 3,10 como lenguaje principal; bibliotecas de análisis de datos: Pandas y NumPy; procesamiento geoespacial: Rasterio y Geopandas; Aprendizaje Profundo: PyTorch 2,1 y Torchvision.

### ***Adquisición y preprocesamiento de datos multiespectrales***

El flujo de datos se gestionó mediante la API de Python de GEE [1], [4]. Se filtraron colecciones de imágenes desde el 1 de octubre hasta el 31 de mayo de cada ciclo, coincidiendo con el calendario fenológico oficial [11]. Las imágenes seleccionadas cuentan con correcciones atmosféricas, topográficas y de reflectancia de superficie pre-ejecutadas.

Se generó una colección de cinco Índices de Vegetación (IV): NDVI, GNDVI, NDRE, EVI y SAVI. Debido a que el sensor Sentinel-2 captura la banda de borde rojo (Red Edge) a 20 m, el índice NDRE fue remuestreado a 10 m mediante una interpolación bilineal para asegurar la alineación de píxeles con las bandas visibles e infrarrojas [1]. Posteriormente, las imágenes se segmentaron en parches (patches) de  $64 \times 64$  píxeles (40,96 ha), descartando aquellos con una cobertura de arroz inferior al 10 % para minimizar el ruido espectral proveniente de otras coberturas de suelo [2], [3].

### ***Etiquetado fenológico y preparación del dataset***

La definición de las clases se fundamentó en una aproximación híbrida que combina el calendario de siembra/cosecha con el comportamiento de las series temporales de NDVI:

- Etapa vegetativa. Desde la inundación hasta el macollamiento ( $\text{NDVI} \approx 0,3-0,7$ ) [12].
- Etapa reproductiva. Del inicio de la panícula al llenado de grano ( $\text{NDVI} > 0,8$  descendiendo gradualmente).
- Etapa de maduración. De la madurez fisiológica a la cosecha ( $\text{NDVI} < 0,6$ ).

Las fechas de transición se ajustaron por municipio y año para considerar la variabilidad regional y ambiental [4]. Las imágenes satelitales de la finca (recortadas a las dimensiones del

bounding box de la finca) se enmascararon con las máscaras de arroz disponibles en línea [13]. El *dataset* final de 1.533 muestras se particionó en conjuntos de entrenamiento (70 %), validación (15 %) y prueba (15 %). Se aplicó una estandarización global por canal, calculando la media ( $\mu$ ) y desviación estándar ( $\sigma$ ) de cada índice para normalizar la entrada del modelo.

### ***Arquitectura del modelo y entrenamiento***

Se implementó una arquitectura ResNet-18 con pesos preentrenados en ImageNet para aprovechar la extracción de características visuales base (*transfer learning*) [2], [3]. Se realizó un ajuste fino (*fine-tuning*) bajo una estrategia de congelamiento de capas: las capas convolucionales originales permanecieron estáticas, centrando el aprendizaje en una nueva capa de entrada adaptada a los 5 canales espectrales y una capa de salida densa de 3 neuronas.

El modelo integra un total de 11.184.323 parámetros, con 17.219 parámetros entrenables, lo que minimiza el riesgo de sobreajuste (*overfitting*) dado el tamaño del dataset.

El entrenamiento se configuró con:

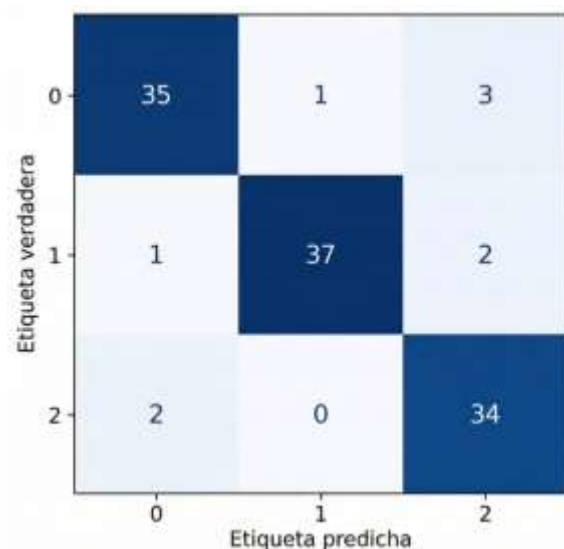
- Función de pérdida. Entropía cruzada (*Cross-entropy loss*).
- Optimización. Tasa de aprendizaje de 0,0001 durante 50 épocas.
- Regularización. *Early Stopping* con paciencia de 5 épocas basado en la pérdida de validación [4].

## **Resultados y discusión**

El modelo ResNet-18 demostró un desempeño excepcional en la clasificación fenológica multiclase, alcanzando una exactitud global del 92,17 % y un índice Kappa de 88,26 % en el conjunto de prueba independiente. Este último valor es particularmente relevante, ya que confirma un nivel de concordancia "casi perfecto" que trasciende el azar estadístico. Las métricas de precisión (92,22 %), sensibilidad (recall) (92,23 %) y F1-score (92,15 %) evidencian un equilibrio robusto en la detección de las tres fases analizadas (vegetativa, reproductiva y maduración).

La efectividad del enfoque propuesto radica en la integración de una firma espectral enriquecida mediante cinco índices de vegetación (NDVI [14], GNDVI, NDRE, EVI, SAVI). Esta combinación permitió capturar dinámicas complejas en parcelas fragmentadas de Rio Grande do Sul, superando las limitaciones de los métodos tradicionales basados en umbrales fijos de NDVI, los cuales suelen reportar márgenes de error de entre el 15 % y 20 % debido a la interferencia del ruido de fondo del suelo y la persistencia de nubosidad parcial.

El proceso de entrenamiento, optimizado mediante Early Stopping, garantizó la convergencia del modelo evitando el sobreajuste. El análisis detallado de la matriz de confusión (Figura 2) revela que la mayor tasa de error (7 %) se concentra en la transición entre las etapas vegetativa y de maduración, comportamiento atribuible a similitudes espectrales en periodos de baja densidad foliar. No obstante, la arquitectura de transferencia de aprendizaje validada permite la generación de mapas fenológicos dinámicos en tiempo casi real, proporcionando una base técnica sólida para la gestión agronómica de precisión.



**Figura 2.** Evaluación del rendimiento del modelo mediante la matriz de confusión.

Los resultados cuantifican la capacidad del sistema para discriminar las etapas fenológicas del arroz, destacando la alta diagonalidad y la mínima tasa de falsos positivos entre clases críticas.

La principal implicación de estos resultados reside en la demostración de que las arquitecturas de aprendizaje profundo, como ResNet-18, pueden extraer patrones espaciales y espectrales jerárquicos que los índices de vegetación aislados omiten. Esta capacidad de generalización convierte al modelo en un artefacto tecnológico esencial para la monitorización a gran escala, permitiendo una transición de la observación manual costosa a un sistema de alerta temprana automatizado. La portabilidad de la solución, validada mediante su ejecución en hardware convencional, abre la posibilidad de su despliegue en infraestructuras de gobernanza agrícola local para la optimización de recursos hídricos y fertilización.

Como líneas de investigación futura, se propone la integración de sensores de radar de apertura sintética (SAR), específicamente Sentinel-1, para evaluar la robustez del sistema en condiciones de nubosidad extrema durante el ciclo de siembra. Asimismo, se plantea la exploración de arquitecturas de atención (Transformers) para el procesamiento de series

temporales completas, lo cual podría reducir aún más el margen de error en las etapas de transición fenológica y permitir la predicción temprana de rendimientos de cosecha con mayor antelación.

## Conclusiones

La presente investigación confirma que la arquitectura ResNet-18, mediante una estrategia de ajuste fino, constituye una herramienta útil para la monitorización fenológica automatizada. Se concluye que la integración de una firma espectral multivariable, compuesta por cinco índices de vegetación, permite al modelo capturar de manera jerárquica las sutiles variaciones morfológicas del cultivo de arroz, superando las limitaciones de saturación y ruido de fondo del suelo que afectan a los índices aislados.

Desde una perspectiva agronómica, la capacidad del modelo para discernir entre las etapas vegetativa, reproductiva y de maduración en diversos contextos temporales y regionales valida su potencial como motor de inferencia en sistemas de agricultura de precisión. El éxito de esta metodología en el estado de Rio Grande do Sul sugiere que el aprendizaje profundo puede democratizar el acceso a información técnica de alto valor, permitiendo a los gestores y productores optimizar el uso de recursos hídricos y químicos de forma proactiva.

Finalmente, el estudio resalta la viabilidad de utilizar imágenes de la constelación Sentinel-2 armonizadas para generar cartografía fenológica dinámica con alta resolución espacial. No obstante, se identifica la persistencia de nubes como el principal factor limitante para la continuidad operativa en regiones subtropicales. En consecuencia, se recomienda que las futuras líneas de investigación exploren la fusión de datos multimodales, integrando sensores activos de radar para garantizar la resiliencia del sistema ante condiciones meteorológicas adversas, avanzando así hacia un monitoreo satelital ininterrumpido y climáticamente inteligente.

## Contribución y autoría

**S.V.:** Conceptualización, procesamiento del conjunto de datos en Python, redacción del manuscrito original y administración del proyecto. **C.S.:** Adaptación de la arquitectura ResNet-18, supervisión del entrenamiento en el ecosistema PyTorch y optimización de hiperparámetros. **E.P.:** Análisis estadístico de resultados, validación cruzada, revisión editorial final y obtención de recursos. Todos los autores han leído y aceptado la versión publicada del manuscrito.

**S.V.:** Conceptualization, dataset processing in Python, writing-original draft preparation, and project administration. **C.S.:** Adaptation of the ResNet-18 architecture, supervision of the training within the PyTorch ecosystem, and hyperparameter optimization. **E.P.:** Statistical analysis of results, cross-validation, final editorial review, and funding acquisition. All authors have read and agreed to the published version of the manuscript.

### **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 la presente investigación se realizó bajo los más estrictos estándares de integridad científica. Dado que el estudio se fundamenta exclusivamente en el procesamiento de imágenes satelitales de acceso abierto (Sentinel-2) y datos vectoriales de fuentes oficiales públicas (CONAB), la metodología no involucró experimentación con seres humanos ni animales. El tratamiento de los datos se ejecutó garantizando el cumplimiento de las normativas vigentes sobre propiedad intelectual y los protocolos de uso de información geoespacial pública.

### **Uso de inteligencia artificial**

Los autores declaran que no se utilizaron herramientas de inteligencia artificial generativa ni tecnologías asistidas por IA para la redacción o preparación del manuscrito. La arquitectura de Aprendizaje Profundo (ResNet-18) descrita en la metodología constituye el objeto de investigación y fue implementada de forma autónoma por los autores mediante programación original. Todo el análisis, interpretación de resultados y redacción del texto son autoría exclusiva de los investigadores.

### **Disponibilidad de datos**

Los conjuntos de datos multiespectrales analizados en este estudio están disponibles de forma pública a través de la API de Google Earth Engine (GEE) utilizando el ecosistema de Python. El catálogo completo de colecciones de Sentinel-2 y los parámetros de procesamiento pueden consultarse en el repositorio oficial de [GEE Data Catalog](#).

Asimismo, los datos vectoriales correspondientes a las poligonales de los cultivos de arroz por municipio y estado en Brasil fueron obtenidos de la Compañía Nacional de

Abastecimiento (CONAB) y se encuentran disponibles para su descarga en el [Portal de Informaciones de la CONAB](#).

### **Conflictos de intereses**

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

### **Referencias**

- [1] G. Xie y S. Niculescu, «Mapping Crop Types Using Sentinel-2 Data Machine Learning and Monitoring Crop Phenology with Sentinel-1 Backscatter Time Series in Pays de Brest, Brittany, France», *Remote Sensing*, vol. 14, n.º 18, p. 4437, sep. 2022, doi: 10.3390/rs14184437.
- [2] A. Nazir *et al.*, «Estimation and Forecasting of Rice Yield Using Phenology-Based Algorithm and Linear Regression Model on Sentinel-II Satellite Data», *Agriculture*, vol. 11, n.º 10, p. 1026, oct. 2021, doi: 10.3390/agriculture11101026.
- [3] G. Tian *et al.*, «An Automatic Method for Rice Mapping Based on Phenological Features with Sentinel-1 Time-Series Images», *Remote Sensing*, vol. 15, n.º 11, p. 2785, may 2023, doi: 10.3390/rs15112785.
- [4] J. Wang *et al.*, «Estimation of rice phenology date using integrated HJ-1 CCD and Landsat-8 OLI vegetation indices time-series images», *J. Zhejiang Univ. Sci. B*, vol. 16, n.º 10, pp. 832-844, oct. 2015, doi: 10.1631/jzus.B1500087.
- [5] T. N. Matongera, O. Mutanga, M. Sibanda, y J. Odindi, «Estimating and Monitoring Land Surface Phenology in Rangelands: A Review of Progress and Challenges», *Remote Sensing*, vol. 13, n.º 11, p. 2060, may 2021, doi: 10.3390/rs13112060.
- [6] J. Segarra, M. L. Buchailot, J. L. Araus, y S. C. Kefauver, «Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications», *Agronomy*, vol. 10, n.º 5, p. 641, may 2020, doi: 10.3390/agronomy10050641.
- [7] P. Ebel, A. Meraner, M. Schmitt, y X. X. Zhu, «Multisensor Data Fusion for Cloud Removal in Global and All-Season Sentinel-2 Imagery», *IEEE Trans. Geosci. Remote Sensing*, vol. 59, n.º 7, pp. 5866-5878, jul. 2021, doi: 10.1109/TGRS.2020.3024744.

- [8] R. Abdollahi-Arpanahi, D. Gianola, y F. Peñagaricano, «Deep learning versus parametric and ensemble methods for genomic prediction of complex phenotypes», *Genet Sel Evol*, vol. 52, n.º 1, p. 12, dic. 2020, doi: 10.1186/s12711-020-00531-z.
- [9] Z. Yi, L. Jia, y Q. Chen, «Crop Classification Using Multi-Temporal Sentinel-2 Data in the Shiyang River Basin of China», *Remote Sensing*, vol. 12, n.º 24, p. 4052, dic. 2020, doi: 10.3390/rs12244052.
- [10] A. Htitiou, A. Boudhar, Y. Lebrini, R. Hadria, H. Lionboui, y T. Benabdelouahab, «A comparative analysis of different phenological information retrieved from Sentinel-2 time series images to improve crop classification: a machine learning approach», *Geocarto International*, vol. 37, n.º 5, pp. 1426-1449, mar. 2022, doi: 10.1080/10106049.2020.1768593.
- [11] CONAB, «Calendário de Plantio e Colheita de Grãos no Brasil 2022». CONAB, Brasil, 2022. [En línea]. Disponible en: <https://www.gov.br/conab/pt-br/aceso-a-informacao/institucional/publicacoes/arquivos-de-paginas/calendariozplantiozezcolheitazjunz2022.pdf>
- [12] L. Wang, F. Zhang, Y. Jing, X. Jiang, S. Yang, y X. Han, «Multi-Temporal Detection of Rice Phenological Stages Using Canopy Spectrum», *Rice Science*, vol. 21, n.º 2, pp. 108-115, mar. 2014, doi: 10.1016/S1672-6308(13)60170-5.
- [13] CONAB, «Mapeamentos Agrícolas». 2025. [En línea]. Disponible en: <https://portaldeinformacoes.conab.gov.br/mapeamentos-agricolas-downloads.html>
- [14] M. Pompa-García *et al.*, «NDVI Values Suggest Immediate Responses to Fire in an Uneven-Aged Mixed Forest Stand», *Forests*, vol. 13, n.º 11, p. 1901, nov. 2022, doi: 10.3390/f13111901.

### 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.