

Della Bellver, F.; Franch Gras, B.; Tarin Mestre, J.; Guerrero Benavent, C.; Domingo Carrasco, C.; Català Forner, M.; Martí, K.; Marqués, L. Influencia de la variabilidad varietal del arroz en la clasificación de niveles de nitrógeno mediante teledetección

# Influencia de la variabilidad varietal del arroz en la clasificación de niveles de nitrógeno mediante teledetección

**Della Bellver, Fátima<sup>1</sup> Franch Gras, Belen<sup>1,2</sup> Tarin Mestre, Javier<sup>1</sup> Guerrero Benavent, Cesar José<sup>1</sup> Domingo Carrasco, Concha<sup>3</sup> Català Forner, Mar<sup>4</sup> Martí, Karen<sup>4</sup> Marqués, Luis<sup>5</sup>**

<sup>1</sup> Global Change Unit, IPL, Universitat de València, Paterna, 46980 Valencia, España

<sup>2</sup> Department of Geographical Sciences, University of Maryland, College Park, MD, USA

<sup>3</sup> Institut Valencià d'Investigacions Agràries (IVIA), Moncada, 46113 Valencia, España

<sup>4</sup> Institut de Recerca i Tecnologia Agroalimentàries (IRTA), Amposta, 43870, Tarragona, España

<sup>5</sup> COPSEMAR, Sueca, 46410 Valencia, España

ORCID: Franch Gras [0000-0003-0593-7874](https://orcid.org/0000-0003-0593-7874) Català Forner [0000-0002-1026-7097](https://orcid.org/0000-0002-1026-7097)

Correspondencia: [fatima.della@uv.es](mailto:fatima.della@uv.es) [belen.franch@uv.es](mailto:belen.franch@uv.es) [tamesja@uv.es](mailto:tamesja@uv.es) [cesar.guerrero@uv.es](mailto:cesar.guerrero@uv.es)  
[domingo\\_concar@gva.es](mailto:domingo_concar@gva.es) [Mar.Catala@irta.cat](mailto:Mar.Catala@irta.cat) [karen.marti@irta.cat](mailto:karen.marti@irta.cat) [luismarques@copsemar.com](mailto:luismarques@copsemar.com)

## RESUMEN

El arroz (*Oryza sativa* L.) es un cultivo básico a nivel mundial, siendo España el segundo productor europeo. Sin embargo, el sector afronta importantes retos ambientales derivados del cambio climático y la creciente demanda de agua. Aunque la teledetección ofrece herramientas para optimizar insumos como el nitrógeno (N), muchos modelos actuales están calibrados para variedades específicas, lo que limita su aplicabilidad. Este estudio evalúa la transferibilidad de modelos de RS para monitorizar el estado de fertilización nitrogenada en un conjunto altamente heterogéneo de genotipos, localizaciones y campañas. Se realizaron ensayos en seis sitios experimentales de Valencia y Tarragona durante 2022 y 2023, incluyendo más de 170 variedades comerciales y otras en desarrollo, bajo dos dosis de N (100 y 200 kg N/ha). Las imágenes multiespectrales de UAV (MAIA S2) se utilizaron para entrenar clasificadores Random Forest, con el fin de diferenciar entre dosis de N. Los clasificadores lograron más del 85% de exactitud en varias localizaciones, mostrando que las bandas del visible son más relevantes en etapas tempranas, mientras que el infrarrojo cercano y el red-edge son clave durante todo el ciclo. El 82% de las variedades mostró alta compatibilidad con el modelo global de N. En conclusión, la monitorización del nivel de nitrógeno mediante clasificadores RF y teledetección con UAVs es robusta frente a la variabilidad genética.


**Palabras clave:** *Variedades de arroz, clasificación de nitrógeno, Random Forest*

Fecha de recepción: 18 febrero 2026 · Fecha de aceptación: 20 febrero 2026


# Influencia de la variabilidad varietal del arroz en la clasificación de niveles de nitrógeno mediante teledetección

Della Bellver, Fàtima <sup>(1)</sup>, Franch Gras, Belen <sup>(1,2)</sup>, Tarin Mestre, Javier <sup>(1)</sup>, Guerrero Benavent, Cesar José <sup>(1)</sup>, Domingo Carrasco, Concha <sup>(3)</sup>, Català Forner, Mar <sup>(4)</sup>, Martí, Karen <sup>(4)</sup>, Marqués, Luis <sup>(5)</sup>

<sup>(1)</sup> Global Change Unit, IPL, Universitat de València, Paterna Valencia, España.  
fatima.della@uv.es; tamesja@uv.es ; cesar.guerrero@uv.es

<sup>(2)</sup> Department of Geographical Sciences, University of Maryland, USA.  
 0000-0003-0593-7874, belen.franch@uv.es

<sup>(3)</sup> Institut Valencià d'Investigacions Agràries (IVIA), Moncada Valencia, España.  
domingo\_concar@gva.es

<sup>(4)</sup> Institut de Recerca i Tecnologia Agroalimentàries (IRTA), Amposta, España.  
 0000-0002-1026-7097, Mar.Catala@irta.cat ; karen.marti@irta.cat

<sup>(5)</sup> COPSEMAR, Sueca Valencia, España.  
luismarques@copsemar.com

**Resumen:** El arroz (*Oryza sativa* L.) es un cultivo básico a nivel mundial, siendo España el segundo productor europeo. Sin embargo, el sector afronta importantes retos ambientales derivados del cambio climático y la creciente demanda de agua. Aunque la teledetección ofrece herramientas para optimizar insumos como el nitrógeno (N), muchos modelos actuales están calibrados para variedades específicas, lo que limita su aplicabilidad. Este estudio evalúa la transferibilidad de modelos de RS para monitorizar el estado de fertilización nitrogenada en un conjunto altamente heterogéneo de genotipos, localizaciones y campañas. Se realizaron ensayos en seis sitios experimentales de Valencia y Tarragona durante 2022 y 2023, incluyendo más de 170 variedades comerciales y otras en desarrollo, bajo dos dosis de N (100 y 200 kg N/ha). Las imágenes multiespectrales de UAV (MAIA S2) se utilizaron para entrenar clasificadores Random Forest, con el fin de diferenciar entre dosis de N. Los clasificadores lograron más del 85% de exactitud en varias localizaciones, mostrando que las bandas del visible son más relevantes en etapas tempranas, mientras que el infrarrojo cercano y el *red-edge* son clave durante todo el ciclo. El 82% de las variedades mostró alta compatibilidad con el modelo global de N. En conclusión, la monitorización del nivel de nitrógeno mediante clasificadores RF y teledetección con UAVs es robusta frente a la variabilidad genética.

**Palabras clave:** Arroz, fertilización, nitrógeno, Random Forest, UAV

## ***Influence of rice varietal variability on nitrogen level classification using remote sensing***

**Abstract:** Rice (*Oryza sativa* L.) is a globally important staple crop, and Spain is the second-largest producer in Europe. However, the sector faces significant environmental challenges driven by climate change and increasing water demand. Although remote sensing provides tools to optimize inputs such as nitrogen (N), many current models are calibrated for specific varieties, limiting their applicability. This study evaluates the transferability of RS-based models to monitor nitrogen fertilization status across a highly heterogeneous dataset of genotypes, locations, and seasons. Field trials were conducted at six experimental sites in Valencia and Tarragona during the 2022 and 2023 seasons, including more than 170 commercial cultivars and other on-development lines, under two N rates (100 and 200 kg N/ha). Multispectral UAV imagery (MAIA S2) was used to train Random Forest classifiers, that were applied to discriminate N rates. The classifiers achieved over 85% accuracy at several locations, showing that visible bands are more relevant at early growth stages, while near-infrared and red-edge bands remain key throughout the crop cycle. Overall, 82% of the varieties showed high compatibility with the global N classification model. In conclusion, RS-based nitrogen level monitoring is robust to genetic variability.

## 1. INTRODUCCIÓN

El arroz (*Oryza sativa* L.) es un cultivo básico de importancia global. España se situó como el segundo mayor productor de la UE en 2025, con un 26% del total (Comisión Europea, 2026). El cambio climático está impactando la producción arrocerca (Farooq *et al.*, 2023), lo que exige sistemas más resilientes, adaptativos y tecnológicamente avanzados que usen, entre otras tecnologías, la teledetección (Shukla *et al.*, 2025). En arroz, los estudios de fertilización y nutrición suelen emplear teledetección hiperespectral mediante drones (Yang *et al.*, 2025), aunque también se emplean sensores multispectrales para estos fines (Xu *et al.*, 2023). La mayoría de los trabajos se centran en una variedad única, y es que varios estudios demuestran la influencia de la variedad de arroz al modelizar datos espectrales (Franch *et al.*, 2021).

En este contexto, durante el proyecto BestRice, se realizó un estudio sin precedentes que incluyó 170 genotipos, principalmente japónicos, junto con otras 170 variedades en desarrollo (MAGIC) evaluadas por el IVIA. El diseño experimental implicó someter diversas parcelas a déficits y excedentes de nitrógeno (N) para evaluar las respuestas fenotípicas y las similitudes genéticas. Este artículo busca aprovechar dicho esfuerzo para estudiar los problemas de la diferenciación de la tasa de N y la predicción del rendimiento mediante teledetección, considerando a su vez la influencia de la diversidad genética del arroz y comprendiendo la transferibilidad de los modelos entre variedades. En particular, se entrena un clasificador de *Random Forest* (RF) para categorizar los campos según su nivel de fertilización y posteriormente se analiza qué variedades pueden ser englobadas en dicho clasificador general.

Se abordan las siguientes cuestiones científicas:

- ¿Se puede utilizar un clasificador RF único para monitorear el nivel de fertilización de diferentes variedades de arroz? De no ser así, ¿cuántas variedades puede capturar?

En respuesta, se proponen la siguiente hipótesis:

- Los clasificadores de niveles de fertilización serán transferibles entre variedades, ya que clasifican rangos (bajo/alto) y, además, se aplican en fases tempranas donde la respuesta al N es relativamente universal.

## 2. MATERIALES Y MÉTODOS

### 2.1.1. Zona de estudio

El estudio se realizó en tres sitios experimentales en España: dos en Sueca (Valencia), gestionados por el *Institut Valencià d'Investigacions Agràries* (IVIA) y la cooperativa COPSEMAR.SL, y uno en Amposta (Tarragona), gestionado por el *Institut de Recerca i Tecnologia Agroalimentàries* (IRTA). Se evaluaron las campañas 2022 y 2023 en IRTA e IVIA, y 2023 en COPSEMAR. Los ensayos consistieron en parcelas

compactas con 30 plantas trasplantadas en estado BBCH 14 (~20 DAS), bajo inundación constante (5–10 cm), con variedades replicadas a dosis de N bajo (LND) (100 kg N ha<sup>-1</sup>) y alto (HND) (200 kg N ha<sup>-1</sup>). El diseño contó con dos variedades testigo (*JSendra* y *Argila*), repetidas con mayor frecuencia. En IRTA y COPSEMAR se utilizaron las mismas 170 variedades comerciales, mientras que en IVIA se analizaron 170 variedades experimentales MAGIC en fase prototipo. La colección de variedades comerciales se organizó en distintos grupos genéticos (*Long grain* (LG), *Spanish II* (S-II), *American/Australian* (AA), *Spanish I* (S-I), *Old Spanish* (OS), *Asian* (As), *Italian* (It), *Índica* (In) y *Bomba group* (BG)). Además, En IVIA 2023, el ensayo con diseño aumentado y tratamientos de fertilización se realizó dos veces, dando lugar a un total de seis ensayos experimentales (tabla 1).

**Tabla 1.** Datos de campo disponibles por sitio y campaña. Se indica el nombre simplificado de cada sitio (A, B, C, D, E, F) y el tipo de conjunto varietal (comercial o MAGIC)

Zona	Año	Nombre	Variedades
COPSEMAR	2023	A	Comerciales
	2022	B	
IRTA	2023	C	MAGIC
	2022	D	
IVIA	2023	E	MAGIC
		F	

El número de vuelos de dron varió según el sitio; en la tabla 2 se puede apreciar la frecuencia de imágenes por zona.

### 2.1.2. MAIA S2

MAIA S2 es una cámara multispectral diseñada para volar a bordo de UAVs con 9 sensores en bandas VIS-NIR equivalentes a Sentinel-2 y resolución de 3 × 3 cm<sup>2</sup> (a 60 m de altura). Las imágenes se procesaron usando *MAIA 1.4.JAG* y *Argisoft Metashape*, utilizando una lona de calibración (*tarp*) con valores de reflectancia conocidos para garantizar la corrección radiométrica.

### 2.1.3. Normalización por GDD

Se utilizan los Grados Día Acumulados (**GDD<sub>accum</sub>**) (ec. 1, 2, 3, 4) para normalizar las series temporales de reflectancia y poder comparar temporadas diferentes mediante la alineación temporal de sus estados fenológicos (Song *et al.*, 2022).

$$GDD_{accum} \text{ (day)} = \sum_{d = \text{biofix date}}^{\text{day}} GDD_d \quad (1)$$

$$GDD_d = \frac{T_{min,d}^* + T_{max,d}^*}{2} - T_{low} \quad (2)$$

$$T_{max,d}^* = \begin{cases} T_{max,d} & \text{if } T_{low} < T_{max,d} < T_{high} \\ T_{low} & \text{if } T_{max,d} \leq T_{low} \\ T_{high} & \text{if } T_{max,d} \geq T_{high} \end{cases} \quad (3)$$

$$T_{max,d}^* = \begin{cases} T_{min,d} & \text{if } T_{low} < T_{min,d} < T_{high} \\ T_{low} & \text{if } T_{min,d} \leq T_{low} \\ T_{high} & \text{if } T_{min,d} \geq T_{high} \end{cases} \quad (4)$$

$T_{max,d}$  y  $T_{min,d}$  corresponden a las temperaturas máximas y mínimas diarias obtenidas del producto diario *2m air temperature* de ERA5-Land, con una resolución espacial de 0.1°.  $T_{low}$  y  $T_{high}$  son umbrales térmicos del cultivo; por encima de  $T_{high}$  la acumulación diaria se satura. Debido a la alta diversidad varietal, se simplificó el enfoque de Song *et al.* (2022) estableciendo los valores de 10 °C ( $T_{low}$ ) y 35 °C ( $T_{high}$ ). Se definieron periodos basados en intervalos de  $GDD_{accum}$ , con la notación  $BX_p$ , donde X es la banda de MAIA S2 y p el número de periodo; cada p corresponde a un rango específico de GDD (tabla 2).

**Tabla 2.** Correspondencia entre el periodo y el intervalo de  $GDD_{accum}$  por localización. También se incluyen los Días Después de la Siembra (DAS) para contextualizar los datos dentro del ciclo del cultivo.

p	GDD	DAS	A	B	C	D	E	F
1	< 300	~30-35						
2	[300, 400)	~40						
3	[400, 500)	~45-50						
4	[500, 600)	~50-55						
5	[600, 700)	~60-70						
6	[700, 800)	~60-70						
7	[800, 890)	~60-70						
8	[890, 980)	~70-80						
9	[980, 1090)	~80-90						
10	[1090, 1150)	~80-90						
11	[1150, 1200)	~90						
12	[1200, 1270)	~90-100						
13	[1270, 1390)	~95-105						
14	[1390, 1500)	~105-115						
15	>= 1500	~115						

#### 2.1.4. Random Forest

Los RF se construyen por zona, entrenando con todas las bandas, incorporadas progresivamente por periodo y aplicando un *K-fold* de 3 iteraciones. Previamente se optimizan los hiperparámetros con *GridSearchCV* y se seleccionan las bandas con importancia SHAP >50%. Los parámetros para la validación son el *accuracy*, el *recall* y el *F1-Score*. Además, considerando todos los RF generados, se establece el criterio de aceptación de variedades, donde una variedad es aceptada si al menos el 70% de sus observaciones fueron correctamente clasificadas.

### 3. RESULTADOS


La Tabla 3 muestra el rendimiento de modelos por sitio y campaña, por simplicidad, se presentan los resultados de las últimas iteraciones, donde se consideran todos los periodos. El mejor desempeño se obtiene en el experimento E, con valores de F1 y *accuracy* de hasta 0,92 y *recalls* entre 0,91–0,97. F también presenta resultados destacados (~0,90), mientras que el peor rendimiento corresponde al sitio D (*accuracy* máximo de

0,73). En cuanto a la importancia espectral, en general las bandas del visible (B01–B04) solo dominan en etapas tempranas, mientras que NDVI, B09, B08, B07 y B06 resaltan en todo el ciclo, ganando relevancia en fases medias y finales.

Respecto a la tolerancia de los modelos a diferentes variedades, en la figura 1 se muestran las tasas de aceptación por grupo genético, indicando tanto el número de variedades como el porcentaje de acierto en cada caso. En general, la mayoría de los grupos presentan valores elevados, con una aceptación global del 82,2%. Destacan especialmente *Spanish I* (88,2%), *MAGIC* (87,4%), *Indica* (85,7%) e *Italian* (84,6%), mientras que los porcentajes más bajos corresponden a *Old Spanish* (66,7,0%), *Spanish II* (76,9%), *Bomba group* (75%) y las variedades sin grupo genético definido (*Non group*: 63,2%). En conjunto, los resultados reflejan un buen desempeño del modelo en la mayoría de los grupos varietales.

**Tabla 3.** Modelos *Random Forest* por ensayo y periodo, mostrando los F1-score, *accuracy* y *recall* (para LND y HND) medios, así como su desviación estándar (provenientes del *K-fold*).

Z	Bandas			F1	Recall LND	Recall HND
	Inicio	Medio	Final			
A	1, 2, 3, 4			0.78 ± 0.016	0.73 ± 0.049	0.84 ± 0.032
B		7, 8, 9, NDVI		0.8 ± 0.015	0.85 ± 0.079	0.76 ± 0.049
C	1, 2, 3, 4, 5, 8			0.85 ± 0.03	0.87 ± 0.035	0.83 ± 0.051
D			6,7,8,9	0.73 ± 0.029	0.77 ± 0.07	0.7 ± 0.015
E	1	9, NDVI	6, 7, 8, 9	0.92 ± 0.052	0.91 ± 0.057	0.93 ± 0.045
F	1, 6, 7, 8,	7, 8, 9, NDVI		0.92 ± 0.024	0.92 ± 0.058	0.93 ± 0.018



**Figura 1.** Proporción de variedades de cada grupo consideradas correctamente clasificadas

### 4. DISCUSIÓN

Los resultados del *Random Forest* muestran que las bandas del visible (VIS) predominan en fases tempranas, mientras que el *Red Edge* (RE) y el NIR aparecen a lo largo de todo el ciclo. Sin embargo, la importancia espectral varía según la zona, la campaña y el conjunto varietal, evidenciando una fuerte dependencia espacial y genética. Esta diferencia en la importancia de las

distintas regiones del espectro se reproduce en varios estudios: Yang *et al.* (2025) encontró que en la fase reproductiva los índices de vegetación que implican bandas VIS y RE-NIR, y otros que incluyen RE-NIR, fueron más influyentes, lo que demuestra que combinar VIS-RE-NIR de mitad y final del ciclo es efectivo. Además, otros estudios también encontraron que los índices derivados de VIS, RE y NIR muestran buena correlación con variables relacionadas con el N (Xu *et al.*, 2023; Tripathi *et al.*, 2025), así como que el NDVI no aparece como una banda única y fiable, igual que en esta investigación. Los patrones de bandas dependen fuertemente del ensayo, ya que estos se realizaron en diferentes campañas y zonas, e incluyen dos conjuntos distintos de variedades: A, B y C contienen variedades comerciales, mientras que D, E y F incluyen variedades en desarrollo. La combinación temporal, espacial y genética de los conjuntos de datos analizados supone una ventaja, dada su falta de precedentes, pero también introduce limitaciones, ya que identificar patrones comunes en condiciones heterogéneas es inherentemente complejo. Resultados comparables se obtuvieron en estudios como el desempeñado por Colorado *et al.* (2020), donde utilizando ocho variedades en un mismo sitio y campaña, concluyeron que además de evaluar la dinámica del N según el estado fenológico, es crucial identificar y clasificar las plantas según su genotipo, dado que el nitrógeno es sensible a diferentes variables como el consumo de oxígeno y crecimiento radicular. Los resultados de la Figura 1 muestran que el 82% de las variedades pueden ser toleradas por los modelos RF. No obstante, al analizar la procedencia genética de las variedades aceptadas, se observa que aunque algunas familias contienen más variedades toleradas, todas contienen tanto casos aceptados como no aceptados, lo que indica que el desempeño del modelo no depende exclusivamente del genotipo. Por tanto, además del origen genético, pueden intervenir otros factores agronómicos, ambientales y fenotípicos en el rendimiento de los modelos RF de clasificación nutricional. Dado el alto porcentaje de variedades toleradas (82%), la hipótesis principal queda validada. Esto demuestra que la clasificación del nitrógeno (N) puede realizarse sin que el genotipo sea un factor necesariamente limitante. Además, estos hallazgos responden a la primera pregunta de investigación al demostrar que los modelos Random Forest pueden clasificar con éxito las dosis de N en diferentes genotipos sin una pérdida significativa de rendimiento.

## 5. CONCLUSIONES

La implementación de la metodología GDD proporciona un marco para la agrupación temporal de datos, permitiendo la integración de diferentes campañas. Al utilizar clasificadores *Random Forest* para diferenciar entre dosis de N, resultados revelan patrones de importancia espectral a lo largo del ciclo: el visible (VIS) es esencial en las primeras fases, mientras que Red Edge (RE) y NIR mantienen relevancia durante todo el ciclo del cultivo. Aunque un hallazgo crítico es la falta de homogeneidad de los modelos entre ensayos. Aunque las grandes regiones espectrales muestran patrones consistentes, estos no se traducen en bandas

individuales concretas. Los clasificadores RF de niveles de N pueden tolerar un elevado número de variedades, lo cual responde a la primera pregunta de investigación, al demostrar que los modelos de clasificación RF pueden discriminar dosis de N en genotipos diversos sin pérdida significativa de rendimiento, validando así la primera hipótesis. Este estudio demuestra que se pueden integrar diversos genotipos de arroz dentro de un mismo esquema de monitorización nutricional.

## 6. AGRADECIMIENTOS

Este estudio forma parte del programa Best Rice y ha sido respaldado por el Ministerio de Ciencia e Innovación (MCIN).

## 7. REFERENCIAS

- Colorado, J. D., Cera-Bornacelli, N., Caldas, J. S., Petro, E., Rebolledo, M. C., Cuellar, D., Calderon, F., Mondragon, I. F., & Jaramillo-Botero, A. (2020). Estimation of Nitrogen in Rice Crops from UAV-Captured Images. *Remote Sensing*, 12(20), 3396. <https://doi.org/10.3390/rs12203396>
- Farooq, M. S., Fatima, H., Rehman, O. U., Yousuf, M., Kalsoom, R., Fiaz, S., Khan, M. R., Uzair, M., & Huo, S. (2023). Major challenges in widespread adaptation of aerobic rice system and potential opportunities for future sustainability. *South African Journal of Botany*, 159, 231–251. <https://doi.org/10.1016/j.sajb.2023.06.017>
- Franch, B., Bautista, A. S., Fita, D., Rubio, C., Tarrázó-Serrano, D., Sánchez, A., Skakun, S., Vermote, E., Becker-Reshef, I., & Uris, A. (2021). Within-Field Rice Yield Estimation Based on Sentinel-2 Satellite Data. *Remote Sensing*, 13(20), 4095. <https://doi.org/10.3390/rs13204095>
- Shukla, S., Chaudhary, K., Aahana, Phutela, S., Bhutani, R., & Shukla, S. K. (2025). Smart crop varieties and precision agriculture: A way ahead for climate-resilient sustainable agriculture. Kumar, O. O. Babalola, J. S. Panwar, & G. Santoyo (Eds.), *Climate change and agricultural ecosystems* (2.<sup>a</sup> ed., pp. 435–466). Woodhead Publishing. <https://doi.org/10.1016/B978-0-443-26520-4.00027-5>
- Tripathi, R., Tripathy, B. R., Jena, S. S., Swain, C. K., Mohanty, S., Sahoo, R. N., Mohapatra, S. D., & Nayak, A. K. (2025). Predicting nitrogen content in rice using unmanned aerial vehicle based multispectral imaging. *CLEAN – Soil, Air, Water*, 53(10), Article e70048. <https://doi.org/10.1002/clen.70048>
- Xu, S., Xu, X., Zhu, Q., Wang, M., & Guo, Y. (2023). Monitoring leaf nitrogen content in rice based on information fusion of multi-sensor imagery from UAV. *Precision Agriculture*, 24(6), 2327–2349. <https://doi.org/10.1007/s11119-023-10042-8>
- Yang, M.-D., Hsu, Y.-C., Chen, Y.-H., Yang, C.-Y., & Li, K.-Y. (2025). Precision monitoring of rice nitrogen fertilizer levels based on machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 237, 110523. <https://doi.org/10.1016/j.compag.2025.110523>