

Evaluación de dos fuentes de información para determinar ambientes productivos en lotes agrícolas del centro-sur de Entre Ríos y noroeste bonaerense

Assessment of two data sources to delineate productive environments in agricultural fields of south-central Entre Ríos and northwestern Buenos Aires

Carola Gonçalves Vila Cova ¹, Alejandra Cecilia Kemerer ²

cgoncalves@agrarias.unlz.edu.ar, alejandra.kemerer@uner.edu.ar

¹ Instituto de Investigación en Producción Agropecuaria, Ambiente y Salud (IIPAAS), Facultad de Ciencias Agrarias, Universidad Nacional de Lomas de Zamora, Av Juan XXIII y Ruta Pcial Nº 4, Lomas de Zamora (1836), Buenos Aires, Argentina.

² Facultad de Ciencias Agropecuarias, Universidad Nacional de Entre Ríos. Ruta Pcial. Nº 11 Km 10,5. Oro Verde (3100), Entre Ríos, Argentina.

Recibido 01/12/2025; Aceptado: 19/02/2026

Resumen. La delimitación de ambientes productivos intralote es una estrategia clave para optimizar el uso de insumos y mejorar la eficiencia productiva en agricultura de precisión. Este estudio comparó la capacidad de dos fuentes de información — mapas de rendimiento e imágenes satelitales NDVI — para discriminar ambientes productivos en cuatro lotes agrícolas del centro-sur de Entre Ríos y del noroeste bonaerense. Se aplicó una clasificación no supervisada mediante el algoritmo k-means

($k = 3$) sobre datos normalizados y se evaluó la congruencia entre ambas fuentes mediante análisis píxel a píxel. Los resultados mostraron que el rendimiento presentó mayor variabilidad que el NDVI, reflejando de forma más completa las condiciones acumulativas de la campaña. Si bien ambas fuentes permitieron discriminar significativamente entre ambientes, el NDVI tendió a sobrevalorar píxeles clasificándolos en categorías más altas que el rendimiento, posiblemente por saturación en etapas de alta biomasa y por la dependencia de fechas específicas de captura. La congruencia entre clasificaciones varió entre regiones y lotes: fue mayor en Entre Ríos (80,00 % en el lote 1-ER y 59,41 % en el lote 3-ER) y menor en Buenos Aires (48,70 % en el lote 6-BA y 43,99 % en el lote 28-BA). Esta diferencia se asoció a la mayor heterogeneidad edáfica y topográfica en Entre Ríos, vinculada a procesos de erosión hídrica, que estructuran la variabilidad productiva y favorecen una respuesta más coherente del NDVI respecto del rendimiento. Se concluye que las imágenes satelitales de acceso libre constituyen una herramienta complementaria y válida para delimitar ambientes productivos cuando no se dispone de mapas históricos de rendimiento o cuando los mapas disponibles presentan limitaciones de calidad. Futuros estudios deberían evaluar el impacto de incrementar el número de observaciones NDVI por lote, establecer umbrales de variabilidad que orienten decisiones de manejo variable y explorar índices alternativos que superen las limitaciones del NDVI.

Palabras-clave: NDVI; mapas de rendimiento; sensores remotos; variabilidad espacial

Abstract. Delineating within-field productive environments is a key strategy in precision agriculture to optimize input use and enhance production efficiency. This study compared the effectiveness of two data sources—yield maps and NDVI satellite imagery—for identifying productive environments in four agricultural fields located in south-central Entre Ríos and northwestern Buenos Aires, Argentina. An unsupervised classification using the k-means algorithm ($k = 3$) was applied to normalized datasets, and pixel-level congruence between sources was assessed. Yield data exhibited greater variability than NDVI, reflecting cumulative growing conditions more comprehensively. While both sources significantly differentiated productive environments, NDVI tended to overrate pixels by assigning them to higher categories than yield, possibly due to saturation during high-biomass stages and its dependence on specific acquisition dates. Congruence between classifications varied by region and field: it was higher in Entre Ríos (80.00 % in field 1-ER and 59.41 % in field 3-ER) and lower in Buenos Aires (48.70 % in field 6-BA and 43.99 % in field 28-BA). This disparity was attributed to greater edaphic and topographic heterogeneity in Entre Ríos, associated with water erosion processes that structure spatial variability and enhance the alignment of NDVI with yield patterns. It is concluded that freely available satellite imagery constitutes a complementary and valid tool for delineating productive environments when historical yield maps are unavailable or when existing maps present quality limitations. Future research should assess the impact of increasing the number of NDVI observations per field, defining variability thresholds to guide site-specific management decisions, and exploring alternative vegetation indices that overcome NDVI limitations.

Keywords: NDVI; yield maps; remote sensing; spatial variability

Introducción

El sector agrícola enfrenta el desafío de incrementar la producción de alimentos para una población creciente, sin expandir la superficie cultivada, considerando las amenazas del cambio climático y minimizando el impacto ambiental (Basso et al., 2017; Godfray et al., 2010). En este contexto, la agricultura de precisión (AP) surge como un paradigma clave, centrado en el manejo de la variabilidad espacial y temporal de los lotes agrícolas. La delimitación de ambientes productivos, también denominados zonas de manejo (ZM), definidas como áreas internamente homogéneas y heterogéneas entre sí, permite optimizar el uso de insumos, reducir costos y contribuir a mitigar el impacto ambiental de la actividad agrícola (Buttafuoco et al., 2010; Damian et al., 2018; Gebbers y Adamchuk, 2010).

Diversas herramientas permiten detectar esta heterogeneidad espacial y temporal, como monitores de rendimiento y sensores espectrales montados en plataformas satelitales (Zanella et al., 2019; Adamchuk et al., 2011). Los mapas de rendimiento se consideran fundamentales para definir eficientemente los ambientes productivos en cultivos anuales, ya que representan la respuesta integrada del cultivo a las prácticas de manejo y a los factores bióticos y abióticos. Además, brindan información valiosa sobre la variabilidad espacial y temporal. Sin embargo, su validación requiere series históricas y datos de calidad (Vazquez Amabile, 2016).

Por su parte, las imágenes satelitales constituyen una fuente valiosa para delimitar ambientes debido a su fácil adquisición, amplia cobertura, rango de espectros disponibles y acceso a series históricas, lo que aporta mayor robustez al análisis. El enfoque de series temporales es especialmente importante para la identificación de patrones de cultivo recurrentes y estables (Georgi et al., 2018). El Índice de Diferencia Normalizada de Vegetación (NDVI) (Rouse et al., 1974), ampliamente utilizado para estimar vigor y biomasa, presenta una alta correlación con parámetros fisiológicos como el índice de área foliar, la biomasa y la disponibilidad de agua en el suelo (de Oliveira Maia et al., 2023), por lo que constituye una herramienta eficaz para discriminar ambientes productivos. Estudios previos han demostrado que la selección de fechas asociadas a etapas fenológicas críticas, como la floración en cereales como maíz y trigo (Casa y Ovando, 2007; Rudorff y Batista, 1990) e inicio de fructificación en soja (Bariani et al., 2015), maximiza la relación entre señales espectrales y rendimiento final (Segarra et al., 2020).

La validación de sensores remotos frente a mapas de rendimiento ha sido abordada en distintos contextos productivos, con resultados variables. En sistemas subtropicales de Brasil, se reportó una congruencia espacial de hasta el 80 % entre zonas delimitadas por NDVI y rendimiento (Damian et al., 2018). En estudios sobre cebada en España, se observaron correlaciones positivas pero moderadas ($r = 0,48$) y se advirtió que la sensibilidad del índice puede verse afectada por la saturación en etapas de alta biomasa o por la pérdida de verdor durante el secado del grano (Escolà et al., 2017). En Argentina, investigaciones en el sudoeste bonaerense indicaron que el NDVI de Sentinel-2 permitió segregar niveles de rendimiento en maíz, y constituye una herramienta capaz para diferenciar ambientes con alta precisión (Frolla et al., 2020). Estos antecedentes muestran que la delimitación de ambientes productivos a partir de sensores remotos puede presentar grados de coincidencia espacial comparables a los obtenidos

mediante mapas de rendimiento, aunque con variabilidad según el cultivo, el ambiente y la metodología empleada.

En los últimos años ha surgido un marcado interés en el uso de índices de vegetación como alternativa o complemento a los mapas de rendimiento, especialmente en situaciones donde estos últimos no están disponibles o no cumplen con las condiciones de calidad requeridas (Damian et al., 2018). La comparación entre mapas de rendimiento e imágenes de NDVI como fuentes de información podría ser una estrategia de validación cruzada de datos para reforzar la confiabilidad en las decisiones tomadas.

Surge entonces el interrogante sobre si las imágenes satelitales de acceso libre y gratuito son una alternativa factible y confiable para delimitar los ambientes productivos cuando no se dispone de mapas de rendimiento o cuando estos presentan limitaciones en cuanto a su calidad o consistencia. En este sentido, el objetivo de este trabajo fue comparar las ambientaciones realizadas mediante distintas fuentes de información: imágenes históricas de NDVI y mapas de rendimiento, en lotes agrícolas del noroeste bonaerense y del centro-sur entrerriano.

Materiales y métodos


Sitios de estudio

El estudio se realizó en cuatro lotes: dos en la localidad de 20 de Septiembre, Nogoyá, Entre Ríos (lote 1-ER: 88,64 ha; lote 3-ER: 58,15 ha) y dos en Francisco Magnano, Carlos Tejedor, Buenos Aires (lote 6-BA: 105,6 ha; lote 28-BA: 108 ha) (Figuras 1 y 2). Para caracterizar las condiciones edáficas generales de cada sitio, se consultaron las Cartas de Suelos de Entre Ríos (escala 1:100000) y de Buenos Aires (escala 1:50000) disponibles en geoINTA (Instituto Nacional de Tecnología Agropecuaria [INTA], 2025). Además, para los lotes de Entre Ríos se generaron curvas de nivel con una equidistancia de 5 m a partir del Modelo Digital de Elevación MDE-AR v2.1 (resolución espacial 30 m; precisión vertical estimada 3 m), descargado del Instituto Geográfico Nacional (IGN, 2025).

Fuentes de datos y preprocesamiento

Mapas de rendimiento. Para cada lote, se utilizaron al menos tres mapas de rendimiento de cultivos de maíz, soja y trigo (Tabla 1). Los datos brutos se corrigieron y filtraron en QGIS (QGIS, 2023) para eliminar errores asociados al funcionamiento del monitor de rendimiento, tales como cabezal de cosecha levantado, retraso en el comienzo y fin de cosecha, superposición de puntos, melgas con ancho incorrecto y otros errores no relacionados con el funcionamiento normal del monitor de rendimiento, como la identificación de valores extremos, datos por encima o por debajo del rango biológico del cultivo y valores extremos locales donde el rendimiento difería en gran medida con los rendimientos aledaños (Albarenque y Vélez, 2011). Los datos vectoriales se rasterizaron a una resolución de 10 x 10 m. Los píxeles vacíos se completaron con la herramienta Close Gaps (algoritmo de SAGA integrado en QGIS 3.22.7) (QGIS, 2023), y posteriormente se aplicó un filtro gaussiano.


Figura 1.
Ubicación geográfica de los lotes 1-ER y 3-ER (Nogoyá, Entre Ríos).



Nota. Base cartográfica: Google satellite (s.f.). División política: Instituto Geográfico Nacional (2025).

Figura 2.

Ubicación geográfica de los lotes 6-BA y 28-BA (Carlos Tejedor, Buenos Aires).



Nota. Base cartográfica: Google Satellite (s.f.). División política: Instituto Geográfico Nacional (2025).

Imágenes de NDVI. Se descargaron las bandas B4 (rojo) y B8 (infrarrojo cercano) de imágenes Sentinel-2A/2B (Nivel 2A), con resolución espacial de 10 m, del Copernicus Data Space Ecosystem (European Space Agency [ESA], s. f.). La selección priorizó imágenes con nubosidad < 15 % y fechas cercanas a etapas fenológicas críticas de los cultivos (floración en cereales, inicio de fructificación en soja) (Tabla 1). Debido a la ausencia de registros precisos de las fechas de siembra en todos los lotes, se utilizó el portal SATveg (Empresa Brasileira de Pesquisa Agropecuária [Embrapa], s. f.) para analizar la evolución temporal del NDVI y seleccionar fechas cercanas a la maximización del índice. Este criterio permitió identificar de manera indirecta la ventana temporal del período crítico de cada cultivo, facilitando además la diferenciación entre siembras tempranas y tardías. El NDVI se calculó como $(\rho_{B8} - \rho_{B4}) / (\rho_{B8} + \rho_{B4})$, donde ρ representa la reflectancia de cada banda. Se eliminaron los píxeles de borde para evitar efectos de mezcla espectral.

Tabla 1.

Mapas de rendimiento por cultivo y fechas de adquisición de imágenes NDVI utilizadas en cada lote.

Lote	Mapa de Rendimiento	Imagen NDVI
1-ER	Trigo_2018	04-10-2018
	Maíz_2021	09-12-2020
	Soja_2022	10-02-2022
3-ER	Maíz_2021	17-02-2021
	Soja_2022	10-02-2022
	Trigo_2022	03-10-2022
6-BA	Maíz_2018	07-01-2018
	Soja_2020	17-01-2020
	Trigo_2020	18-10-2020
28-BA	Soja_2019	26-12-2018
	Trigo_2019	29-10-2019
	Soja_2021	05-02-2021
	Trigo_2021	07-11-2021

Nota. ER: Entre Ríos; BA: Buenos Aires. Los mapas de rendimiento se identifican como Cultivo_Año de Cosecha. Las fechas de NDVI corresponden a imágenes Sentinel-2 (formato dd-mm-aaaa).

Extracción y normalización de datos

Mediante QGIS se generó una grilla de puntos regulares cada 10 m dentro de cada lote, se excluyeron bordes y zonas no productivas. Con el complemento *Point Sampling Tool*, se extrajo un valor por punto para cada variable, y se obtuvieron dos tablas por lote: una con los datos de rendimiento por cultivo y otra con los valores de NDVI por fecha. Todos los datos de rendimiento y NDVI fueron normalizados respecto a su media para permitir la comparabilidad entre variables y lotes. Cada conjunto

se caracterizó mediante estadísticas descriptivas: media, desviación estándar (DE), coeficiente de variación (CV), mínimo (mín) y máximo (máx).

Durante el procesamiento, se identificaron patrones de franjas en algunas imágenes de NDVI de los lotes 3-ER y 6-BA, posiblemente asociados a diferencias en las fechas de siembra. Para evitar sesgos en el análisis los datos se normalizaron por separado para cada franja y luego se recombinaron para el análisis conjunto. El procesamiento se implementó con scripts en Python (Python Software Foundation, (2021)), mediante concatenación vertical y horizontal de los conjuntos de datos correspondientes a las fechas analizadas. Los scripts se encuentran disponibles bajo solicitud a las autoras.

Clasificación no supervisada y análisis de congruencia

La clasificación se realizó mediante el algoritmo no jerárquico *k-means*. El número óptimo de conglomerados (*k*) se determinó gráficamente, a partir de las curvas de heterogeneidad intragrupo generadas por el software InfoStat versión 2020 (Di Rienzo et al., 2008) tras aplicar el algoritmo y el punto de inflexión en dichas curvas indicó el valor óptimo de *k*.

Para homogenizar el análisis de congruencia, se estableció un *k*=3 para todos los casos, valor que evidenció un cambio de pendiente consistente en todas las curvas. Los conglomerados resultantes se ordenaron según su potencial productivo (alto, medio, bajo) y se utilizó la media como criterio. Para evaluar la significancia de las diferencias entre grupos, se aplicó un análisis de varianza (ANOVA), seguido de una prueba de comparación múltiple de Tukey ($\alpha=0,10$). Previo al análisis de congruencia, las tablas clasificadas fueron convertidas a formato ráster.

La comparación píxel a píxel entre las clasificaciones de rendimiento y NDVI se realizó con la herramienta *Cross classification* del *Semi-Automatic Classification Plugin* de QGIS (SCP) (Congedo, 2023), se consideró NDVI como referencia y rendimiento como la nueva clase asignada. Los píxeles con clasificación idéntica en ambas fuentes de información se definieron como congruentes; los no congruentes fueron categorizados según la clase asignada.

Resultados y discusión

El análisis de los datos mostró que los mapas de rendimiento presentaron en todos los lotes un coeficiente de variación (CV) consistentemente mayor que el de las series de NDVI (Tabla 2). Esto sugiere que el rendimiento captura de manera más completa las condiciones acumulativas a lo largo de la campaña, que abarcan factores ambientales y de manejo. En contraste, el NDVI proporciona una instantánea del estado del cultivo en momentos específicos y puede perder sensibilidad en etapas fenológicas de alta biomasa debido a la saturación del índice, lo que reduce su capacidad para discriminar diferencias dentro de los valores más altos. Estos hallazgos coinciden con lo reportado por de Oliveira et al. (2023), Gu et al. (2013) y Zanella et al. (2019).

Tabla 2.

Coefficientes de variación (%CV) de los mapas de rendimiento y de las imágenes de NDVI para cada lote.

Lote	Fuente	Cultivo/Fecha NDVI	%CV
1-ER	Rendimiento	Trigo_2018	16,62
	Rendimiento	Maíz_2021	19,02
	Rendimiento	Soja_2022	32,33
	NDVI	04/10/2018	3,77
	NDVI	09/12/2020	7,08
	NDVI	10/02/2022	23,48
3-ER	Rendimiento	Maíz_2021	17,89
	Rendimiento	Soja_2022	17,64
	Rendimiento	Trigo_2023	11,98
	NDVI	17/02/2021 (1)	9,83
	NDVI	17/02/2021 (2)	4,88
	NDVI	10/02/2022 (1)	8,56
	NDVI	10/02/2022 (2)	17,64
	NDVI	03/10/2022 (1)	8,31
	NDVI	03/10/2022 (2)	8,00
6-ER	Rendimiento	Maíz_2018	11,81
	Rendimiento	Soja_2020	7,70
	Rendimiento	Trigo_2020	9,78
	NDVI	07/01/2018	10,93
	NDVI	17/01/2020 (1)	6,52
	NDVI	17/01/2020 (2)	6,80
	NDVI	18/10/2020 (1)	4,73
	NDVI	18/10/2020 (2)	5,34
28-BA	Rendimiento	Soja_2019	3,40
	Rendimiento	Trigo_2019	2,99
	Rendimiento	Soja_2021	1,94
	Rendimiento	Trigo_2021	3,38
	NDVI	26/12/2018	8,13
	NDVI	29/10/2019	4,72
	NDVI	05/02/2021	3,28
	NDVI	07/11/2021	5,64

Nota. Los valores entre paréntesis (1) y (2) corresponden a franjas dentro del lote identificadas como posibles fechas de siembra diferidas. Los CV se calcularon sobre los datos crudos de rendimiento y NDVI.

La clasificación no supervisada mediante el algoritmo k-means, con $k=3$, determinado a partir del análisis gráfico de las curvas de heterogeneidad intragrupo, permitió una segmentación robusta y comparable entre fuentes de datos. El ordenamiento de los conglomerados en categorías de alto, medio y bajo potencial resultó estadísticamente significativo ($p < 0,10$) en todos los casos, y valida la capacidad de ambas metodologías para discriminar ambientes productivos (Tabla 3). Estos resultados coinciden con lo reportado por Damian et al. (2018) y refuerzan la utilidad de estas herramientas para la delimitación de ambientes productivos estables.

Tabla 3.

Valores medios de rendimiento y NDVI normalizados por ambiente de productividad en los cuatro lotes.

Lote	Ambiente	Rendimiento	NDVI
1-ER	Alto	1,13 a	1,09 a
	Medio	1,03 b	1,00 b
	Bajo	0,79 c	0,86 c
3-ER	Alto	1,13 a	1,06 a
	Medio	0,99 b	0,97 b
	Bajo	0,80 c	0,84 c
6-BA	Alto	1,04 a	1,04 a
	Medio	1,01 b	0,97 b
	Bajo	0,91 c	0,97 c
28-BA	Alto	1,13 a	1,03 a
	Medio	1,04 b	0,99 b
	Bajo	0,92 c	0,95 c


Nota. En cada columna, los valores seguidos por letras distintas indican diferencias estadísticamente significativas ($p < 0,10$).

El análisis píxel a píxel de congruencia entre las clasificaciones por rendimiento y NDVI, realizado mediante la herramienta de posprocesamiento Cross classification del complemento SCP, reveló importantes diferencias entre lotes y regiones. En Entre Ríos, el lote 1-ER presentó el mayor porcentaje de coincidencia, el 80,00 % de los píxeles fueron clasificados de la misma manera por ambas fuentes, representados en verde en el mapa de congruencia (Figura 3). Le siguió el lote 3-ER, con un 59,41 % de píxeles congruentes. En cambio, en Buenos Aires se observaron menores niveles de coincidencia, 48,70 % en el lote 6-BA y 43,99 % en el lote 28-BA (Figura 4). Los píxeles clasificados de forma diferente se muestran con distintos colores según la combinación de clases asignadas por rendimiento y NDVI, lo que permite visualizar las transiciones entre ambientes.

El análisis del comportamiento de los píxeles no coincidentes reveló que, en general, el NDVI tiende a clasificarlos en una categoría más alta respecto del rendimiento, especialmente en las transiciones de alto a medio potencial. Esta diferencia puede atribuirse a la pérdida de sensibilidad del NDVI en etapas fenológicas de elevada biomasa, donde el índice se satura. Además, trabajar con una única observación puede constituir una limitante, ya que la fecha de adquisición de una imagen sin nubes depende de su coincidencia con una fase fenológica específica, lo cual no siempre guarda una relación directa con el rendimiento final (Ovando et al., 2016). El NDVI también puede captar señales de vigor vegetativo que no se traducen necesariamente en productividad. En este estudio se utilizaron entre tres y cuatro imágenes por lote; sin embargo, considerar un mayor número de observaciones podría mejorar la independencia del análisis respecto del tipo de cultivo y de los cambios temporales.


La mayor congruencia entre NDVI y rendimiento observada en los lotes de Entre Ríos, respecto de los de Buenos Aires, podría deberse a una mayor heterogeneidad edáfica y topográfica, especialmente asociada a procesos de erosión hídrica. Según la Carta de Suelos de Buenos Aires (escala 1:50.000), ambos lotes se ubican en planicies con más del 10 % de cubetas, relieve suave a plano y algunas depresiones internas (Figura 5). Las principales limitantes son los anegamientos temporarios. En este contexto, la variabilidad espacial del suelo sería baja y posiblemente subordinada a las condiciones ambientales de cada campaña, lo que explicaría la menor congruencia entre NDVI y rendimiento registrada en los lotes 6-BA y 28-BA. En contraste, los lotes de Entre Ríos incluyen unidades cartográficas con evidencias de erosión hídrica: la Consociación Aragón y la Asociación San Roque II en el lote 1-ER y la Asociación El Triángulo II en el lote 3-ER (Figura 6). La erosión hídrica es un factor principal de degradación de los suelos en Entre Ríos y ha mostrado una correlación positiva con la pérdida de productividad agrícola (Sosa et al., 2022). En el lote 1-ER, la superposición de la capa clasificada por rendimiento y las curvas de nivel indicó que los ambientes de bajo potencial se ubican sobre lomas y media lomas, coincidiendo con zonas erosionadas. Esto sugiere que la erosión hídrica actúa como factor estructurante de la variabilidad productiva y podría explicar la alta congruencia registrada (80,00 %). En el lote 3-ER, si bien la carta de suelos indica pendientes y escurrimiento, las curvas de nivel no mostraron un patrón definido respecto de los ambientes, lo que sugiere que el relieve no sería el principal organizador de la variabilidad productiva en este caso. Esta situación podría explicar la congruencia intermedia observada (59,41 %), inferior a la registrada en el lote 1-ER.

Figura 3.
Mapas de clasificación y análisis de congruencia para los lotes de Entre Ríos.




Nota. A-C: Clasificación por potencial productivo en el lote 1-ER por rendimiento (A) y por NDVI (B). Mapa de congruencia entre ambas clasificaciones (C). D-F: Clasificación por potencial productivo en el lote 3-ER por rendimiento (D) y por NDVI (E). Mapa de congruencia entre ambas clasificaciones (F). Los mapas de congruencia (C y F) muestran coincidencia y discrepancia entre las clasificaciones por rendimiento y NDVI. Los colores indican las combinaciones de clases asignadas por ambas fuentes.

Figura 4.
Mapas de clasificación y análisis de congruencia para los lotes de Buenos Aires.



Nota. A-C: Clasificación por potencial productivo en el lote 6-BA por rendimiento (A) y por NDVI (B). Mapa de congruencia entre ambas clasificaciones (C) D-F: Clasificación por potencial productivo en el lote 28-BA por rendimiento (D) y por NDVI (E). Mapa de congruencia entre ambas clasificaciones (F). Los mapas de congruencia (C y F) muestran coincidencia y discrepancia entre las clasificaciones por rendimiento y NDVI. Los colores indican las combinaciones de clases asignadas por ambas fuentes.


Figura 5.
Caracterización edáfica, topográfica y productiva de los lotes de Buenos Aires.



Nota. A: Carta de suelos de Buenos Aires (escala 1:50000) con los perímetros de los lotes 6-BA y 28-BA; B: Imagen satelital (Google Satélite, s.f.) con las clasificaciones por rendimiento de los lotes 6-BA y 28-BA.

Figura 6.

Caracterización edáfica, topográfica y productiva de los lotes de Entre Ríos.



Nota. A-B: Lote 1-ER. A: Carta de suelos de Entre Ríos (escala 1:100 000) con el perímetro del lote 1-ER y las curvas de nivel superpuestas; los números indican altitud en metros. B: Imagen satelital (Google Satélite, s.f.) con la clasificación por rendimiento del lote 1-ER. C-D: Lote 3-ER. C: Carta de suelos de Entre Ríos (escala 1:100 000) con el perímetro del lote 3-ER y las curvas de nivel superpuestas; los números indican altitud en metros. D: Imagen satelital (Google Satélite, s.f.) con la clasificación por rendimiento del lote 3-ER.

Conclusiones

Los datos de rendimiento mostraron mayor variabilidad en comparación con los valores de NDVI, lo que sugiere que el rendimiento captura de manera más completa las condiciones acumulativas a lo largo de la campaña. Aunque ambas formas de clasificación, rendimiento y NDVI, fueron eficaces para discriminar significativamente entre tres ambientes, las diferencias entre los valores medios por ambiente se reflejaron con mayor claridad en los datos de rendimiento. El NDVI, al ofrecer una visión instantánea, puede verse afectado por la saturación en etapas de alta biomasa y por la dependencia de fechas específicas de captura. La congruencia entre ambas fuentes varió según el lote y fue mayor en escenarios con procesos de erosión hídrica, donde el NDVI respondió de manera más coherente al patrón espacial de rendimiento. No obstante, la tendencia observada del NDVI a sobrevalorar ambientes podría limitar su aplicabilidad en zonas en las cuales la variabilidad temporal puede ser más relevante que la espacial. En conjunto, las imágenes satelitales de acceso libre se consolidan como una herramienta estratégica complementaria para delimitar ambientes productivos cuando no se dispone de mapas históricos de rendimiento o cuando los mapas disponibles presentan limitaciones de calidad. Para potenciar su aplicabilidad operativa, futuras líneas de investigación deberían evaluar el impacto de incrementar el número de observaciones por lote y de ampliar el número de lotes en zonas agroecológicamente homogéneas, además de establecer umbrales de variabilidad que orienten decisiones de manejo variable y explorar índices alternativos que superen las limitaciones del NDVI.

Referencias bibliográficas

- Adamchuk, V., Viscarra Rossel, R., Sudduth, K. y Schulze Lammers, P. (2011). Sensor Fusion for Precision Agriculture. En *Sensor fusion – Foundation and applications*. InTech. <https://doi.org/10.5772/19983>
- Albarenque, S. M. & Vélez, J. P. (2011). *Técnicas para el procesamiento de mapas de rendimiento*. Estación Experimental Agropecuaria Paraná, Centro Regional Entre Ríos–INTA. Ediciones INTA.
- Bariani, C., Kersten, D., Victoria, N., Carlesso, R., Petry, M., Peripolli, M. y Agrônomo, E. (2015). Monitoramento da fenologia da soja irrigada usando perfis de série temporal de NDVI. *Inovagri International Meeting*, 3. <https://doi.org/10.12702/iii.inovagri.2015-a176>
- Basso, B., Dobrowolski, J. y McKay, C. (2017). From the Dust Bowl to drones to big data: The next revolution in agriculture. *Georgetown Journal of International Affairs*, 18(3), 158–165. <https://doi.org/10.1353/gia.2017.0048>
- Buttafuoco, G., Castrignanò, A., Colecchia, A. S. y Ricca, N. (2010). Delineation of management zones using soil properties and a multivariate geostatistical approach. *Italian Journal of Agronomy*, 5(4), 323–332. <https://doi.org/10.4081/ija.2010.323>
- Casa, A. de y Ovando, G. (2007). Integración del NDVI y del ciclo fenológico de maíz para estimar el rendimiento a escala departamental en Córdoba, Argentina. *Agricultura Técnica*, 67(4), 362–371.
- Congedo, L. (2023). *Semi-Automatic Classification Plugin* [Software]. <https://fromgistors.blogspot.com>

- Damian, J. M., De Castro Pias, O. H., Cherubin, M. R., Da Fonseca, A. Z., Fornari, E. Z. y Santi, A. L. (2018). Applying the NDVI from satellite images in delimiting management zones for annual crops. *Scientia Agrícola*, 77(1). <https://doi.org/10.1590/1678-992x-2018-0055>
- Di Rienzo, J. A., Robledo, C. W., Balzarini, M. G., Casanoves, F., González, L. y Tablada, M. (2008). *InfoStat*. Versión 2020. Grupo InfoStat, FCA, Universidad Nacional de Córdoba. <http://www.infostat.com.ar>
- de Oliveira Maia, F. C., Bufon, V. B. y Leão, T. P. (2023). Vegetation indices as a tool for mapping sugarcane management zones. *Precision Agriculture*, 24(1), 213–234. <https://doi.org/10.1007/s11119-022-09939-7>
- Empresa Brasileira de Pesquisa Agropecuária (Embrapa). (s.f.). *SatVeg: Sistema de análise temporal da vegetação*. [Plataforma de monitoreo] Recuperado en 2024, de <https://www.satveg.cnptia.embrapa.br/satveg/login.html>
- Escolà, A., Badia, N., Arnó, J. y Martínez-Casasnovas, J. A. (2017). Using Sentinel-2 images to implement Precision Agriculture techniques in large arable fields: First results of a case study. *Advances in Animal Biosciences*, 8(2), 377–382. <https://doi.org/10.1017/S2040470017000784>
- European Space Agency (ESA). (s. f.). *Copernicus Data Space Ecosystem* [Base de datos]. Recuperado en 2024, de <https://dataspace.copernicus.eu>
- Frolla, F., Zilio, J. P., Krüger, H., y Tranier, E. A. (2020). *Determinación de ambientes productivos en el sudoeste bonaerense: Comparación de distintas fuentes de información*. En actas del XXVII Congreso Argentino de la Ciencia del Suelo, Corrientes, Argentina. <https://www.suelos.org.ar/sitio/cacs-2020-descarga-de-contribuciones/>
- Gebbers, R. y Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831. <https://doi.org/10.1126/science.1183899>
- Georgi, C., Spengler, D., Itzerott, S. y Kleinschmit, B. (2018). Automatic delineation algorithm for site-specific management zones based on satellite remote sensing data. *Precision Agriculture*, 19(4), 684–707. <https://doi.org/10.1007/s11119-017-9549-y>
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., Pretty, J., Robinson, S., Thomas, S. M. y Toulmin, C. (2010). Food security: The challenge of feeding 9 billion people. *Science*, 327(5967), 812–818. <https://doi.org/10.1126/science.1185383>
- Google. (s.f.). *Google Satellite* [Mapa]. Recuperado en 2025, de <https://www.google.com/maps>
- Gu, Y., Wylie, B. K., Howard, D. M., Phuyal, K. P. y Ji, L. (2013). NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. *Ecological Indicators*, 30, 1–6. <https://doi.org/10.1016/j.ecolind.2013.01.041>
- Instituto Geográfico Nacional (s.f.). *Modelo digital de elevación MDE-AR v2.1 (30 m)* [Datos cartográficos]. Recuperado en 2025, de <https://www.ign.gob.ar>
- Instituto Nacional de Tecnología Agropecuaria (2025). *geoINTA: Plataforma de acceso a información geoespacial del INTA*. <https://geointa.inta.gob.ar>
- Ovando, G., Casa, A. de, Bressanini, L., Martínez, J., Miranda, C., Miretti, D., Melano, F. & Moglia, P. (2016). Metodología para estimar cuál es la fecha óptima de adquisición de imágenes Landsat para

- estimar el rendimiento en un lote de soja en el marco de la agricultura de precisión. *Revista de Tecnología Agropecuaria*, 20, 83–93.
- Python Software Foundation. (2021). *Python (Version 3.8.8)* [Software]. Recuperado en 2025, de <https://www.python.org>
- QGIS Development Team (2023). *QGIS geographic information system* (Versión 3.22.7) [Software]. Open Source Geospatial Foundation. <https://qgis.org>
- Rouse, J. W., Haas, R. H., Schell, J. A. y Deering, D. W. (1974). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation* (NASA/GSFC Type III Final Report). NASA.
- Rudorff, B. F. T. y Batista, G. T. (1990). Spectral response of wheat and its relationship to agronomic variables in the tropical region. *Remote Sensing of Environment*, 31(1), 53–63. [https://doi.org/10.1016/0034-4257\(90\)90076-X](https://doi.org/10.1016/0034-4257(90)90076-X)
- Segarra, J., Buchailot, M. L., Araus, J. L. y Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 1–18. <https://doi.org/10.3390/agronomy10050641>
- Sosa, A., Peltzer, L. F., Cabrera, A., Roda, S., Heinze, C., Saluzzio, M. y Gvozdenovich, J. J. (2022). Impacto de la erosión hídrica y sus prácticas de conservación en una microrregión avícola. En *Actas del XXVIII Congreso Argentino de la Ciencia del Suelo*. Asociación Argentina de la Ciencia del Suelo (AACS), Buenos Aires, Argentina. <https://www.suelos.org.ar/sitio/cacs-2022-descarga-de-contribuciones/>
- Vazquez Amabile, G. (2016). Manejo por ambientes: Conceptos y fertilización variable en el sur de Buenos Aires. En *Actas del XXIV Congreso AAPRESID 2016*, Rosario, Santa Fe, Argentina. https://www.researchgate.net/publication/308691662_Manejo_por_ambientes_conceptos_y_fertilizacion_variable_en_el_sur_de_Bs_As
- Zanella, M. A., de Queiroz, D. M., Valente, D. S. M., Pinto, F. de A. de C. y Santos, N. T. (2019). Management class delimitation in a soybean crop using orbital images. *Engenharia Agrícola*, 39(5), 676–683. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39n5p676-683/2019>