

Validación cruzada y mejora de clasificación supervisada en coberturas de la tierra del partido de Puan mediante GEE y WorldCover



Cross-validation and improvement of supervised land cover classification in the Puan district using GEE and WorldCover

 **Sebastián Arce Cendoya**

Depto. de Geografía y Turismo, Universidad Nacional del Sur, Argentina. Instituto Argentino de Oceanografía, Argentina. CONICET-IADO, Bahía Blanca, Argentina
sebastian.arce@uns.edu.ar

 **Alejandra Mabel Geraldí**

Depto. de Geografía y Turismo, Universidad Nacional del Sur, Argentina. Instituto Argentino de Oceanografía, Argentina. CONICET-IADO, Argentina
ageraldi@criba.edu.ar

 **Federico Gastón Barragán**

Depto. de Geografía y Turismo, Universidad Nacional del Sur, Bahía Blanca, Argentina
federico.barragan@uns.edu.ar

Párrafos Geográficos

vol. 25, núm. 1, p. 61, 2026

Universidad Nacional de la Patagonia San Juan Bosco, Argentina

ISSN: 1853-9424

ISSN-E: 1666-5783

Periodicidad: Semestral

parrafosgeograficos@fhcs.unp.edu.ar

Recepción: 30 marzo 2026

Aprobación: 11 junio 2026

URL: <https://portal.amelica.org/ameli/journal/739/7395700002/>

Resumen: El análisis de las coberturas de la tierra es fundamental para comprender la organización y dinámica de los paisajes, especialmente en regiones semiáridas como el partido de Puan, caracterizadas por alta heterogeneidad y coexistencia de usos agropecuarios y coberturas naturales. En este contexto, la validación y el refinamiento de clasificaciones supervisadas resultan esenciales para asegurar la confiabilidad de los productos a escala local.

El objetivo de este estudio fue validar una clasificación supervisada de coberturas de la tierra y evaluar el impacto de técnicas de postclasificación sobre su precisión y coherencia espacial, utilizando como referencia el producto global ESA WorldCover. La metodología incluyó: (i) una clasificación preexistente basada en imágenes Sentinel-2 (10 m) y el algoritmo Random Forest; (ii) validación externa mediante muestreo aleatorio estratificado y métricas de precisión; y (iii) postclasificación mediante análisis de mayoría y filtro sieve.

Los resultados indican que la clasificación inicial presentó una precisión global de 0,61 y un coeficiente Kappa de 0,54. Tras el postprocesamiento, la precisión superó 0,80 (Kappa $\approx$ 0,78–0,79), reduciendo el efecto “sal y pimienta” y mejorando la coherencia espacial. No obstante, persisten limitaciones en la detección de coberturas de pequeña escala, evidenciando un compromiso entre homogeneización y detalle espacial.

Palabras clave: Procesamiento Digital, Coberturas de la Tierra, Postclasificación, ESA Worldcover.

Abstract: Land cover analysis is essential for understanding landscape organization and dynamics, particularly in semi-arid regions such as the Partido de Puan, characterized by high heterogeneity and the coexistence of agricultural uses and natural covers. In this context, the validation and refinement

of supervised classifications are crucial to ensure the reliability of products at the local scale.

The main objective of this study was to validate a supervised land cover classification and to assess the impact of post-classification techniques on its thematic accuracy and spatial coherence, using the global ESA WorldCover product as an external reference. The methodology included: (i) a pre-existing classification based on Sentinel-2 imagery (10 m) and the Random Forest algorithm; (ii) external validation through stratified random sampling and accuracy metrics; and (iii) post-classification using majority analysis and sieve filtering.

The results show that the initial classification achieved an overall accuracy of 0.61 and a Kappa coefficient of 0.54. After post-processing, accuracy exceeded 0.80 (Kappa $\approx$ 0.78–0.79), reducing the “salt-and-pepper” effect and improving spatial coherence. However, limitations persist in detecting small-scale land covers, highlighting a methodological trade-off between spatial homogenization and the preservation of local detail.

Keywords: Digital Image Processing, Land Cover, Post-classification, ESA WorldCover.

Introducción

Las coberturas de la tierra constituyen la representación biofísica de la superficie terrestre, comprendiendo tanto elementos naturales — siendo vegetación, cuerpos de agua y suelos desnudos— como componentes antrópicos asociados a la ocupación y transformación del territorio. Su identificación resulta fundamental para interpretar los procesos geomorfológicos, hidrológicos y ecológicos que estructuran el paisaje (Di Gregorio, 2005; Posada y Salvatierra, 2016).

En contextos locales como el partido de Puan, su análisis adquiere especial relevancia debido a las transformaciones agrícolas recientes y al incremento de eventos climáticos extremos que afectan la dinámica de los ecosistemas. Si bien los productos globales constituyen referencias valiosas para comparaciones regionales, es en la escala local donde se manifiestan con mayor claridad los cambios en el uso y cobertura de la tierra. Esta escala permite captar la heterogeneidad espacial, identificar mosaicos agropecuarios y reconocer parches de vegetación natural, humedales o cuerpos de agua someros que suelen ser invisibilizados en análisis de menor resolución (Turner, 1989, Wu, 2004).

Diversos estudios destacan que la resolución espacial y la escala de análisis influyen significativamente en la precisión y utilidad de los productos derivados. Marceau (1999) señala que muchos procesos ambientales sólo pueden comprenderse adecuadamente a escalas locales, mientras que Turner (1989) y Wu (2004) enfatizan la dependencia de los patrones ecológicos respecto de la escala considerada. En esta línea, investigaciones recientes evidencian mejoras en la clasificación de coberturas al emplear resoluciones espaciales, temporales y espectrales más detalladas, particularmente en paisajes heterogéneos (Ullah et al., 2017), así como en análisis multiresolución que muestran efectos directos de la escala sobre la exactitud (Liu et al., 2020, Li et al., 2023). Asimismo, la integración de imágenes de alta resolución con datos de campo y plataformas en la nube ha permitido generar información más precisa y aplicable a la gestión territorial (Gorelick et al., 2017), en línea con trabajos previos que sirven como base para el refinamiento de productos locales (Arce Cendoya et al., 2024). En conjunto, estas contribuciones destacan el valor de la escala local tanto para mejorar la precisión técnica como para fortalecer la toma de decisiones.

El procesamiento digital de imágenes constituye un método central en el estudio de coberturas, al permitir la obtención sistemática y multiescala de información. En particular, sensores ópticos como Sentinel-2 han ampliado significativamente las capacidades de monitoreo, al ofrecer imágenes multispectrales de 10 m de

resolución y alta frecuencia temporal (Drusch et al., 2012). La combinación de resolución espacial adecuada para distinguir unidades de paisaje y resolución temporal suficiente para captar dinámicas fenológicas permite abordar procesos como la expansión agrícola, la urbanización o la degradación ambiental bajo esquemas de monitoreo continuo (Roy et al., 2014, Wulder et al., 2019).

En este contexto, el desarrollo de plataformas de procesamiento en la nube, como Google Earth Engine (GEE), ha transformado el análisis geoespacial al permitir el acceso y procesamiento de grandes volúmenes de datos sin restricciones computacionales significativas (Gorelick et al., 2017). Esta infraestructura ha facilitado la implementación de algoritmos de clasificación y la generación de productos derivados de manera eficiente y escalable.

No obstante, a pesar de estos avances, los datos de cobertura de la tierra presentan limitaciones relevantes. La información disponible suele encontrarse fragmentada, con escalas variables, resoluciones insuficientes para estudios locales y series temporales inconsistentes (Winkler et al., 2021). Aunque existen colecciones satelitales extensas, su resolución espacial no siempre resulta adecuada para capturar el nivel de detalle requerido en análisis locales (Phiri y Morgenroth, 2017), donde la precisión espacial es determinante.

En este marco, la validación de clasificaciones constituye una etapa fundamental, ya que permite evaluar en qué medida los resultados representan la realidad observada. Este proceso implica la comparación de las clases asignadas con datos de referencia independientes, obtenidos mediante trabajo de campo, fotointerpretación o productos previamente validados (Congalton y Green, 2009). El procedimiento estándar se basa en la construcción de matrices de confusión, que organizan la correspondencia entre clases observadas y predichas (Landis y Koch, 1977).

Entre los productos globales más relevantes se destaca ESA WorldCover, desarrollado a partir de datos Sentinel-1 y Sentinel-2 mediante algoritmos de aprendizaje automático, con resolución de 10 m y cobertura global estandarizada (Bie et al., 2023). Este producto constituye un insumo valioso tanto para análisis comparativos como para validación externa de clasificaciones locales. Sin embargo, presenta limitaciones asociadas a la variabilidad regional y a errores de asignación a nivel de píxel. En particular, el sesgo de incorporación puede surgir cuando estos productos se utilizan como referencia sin validación independiente, lo que puede conducir a la reproducción de errores sistemáticos (Hao et al., 2023). Asimismo, la exactitud global reportada puede ocultar diferencias significativas entre clases y regiones (Xu et al., 2024).

Un problema recurrente en las clasificaciones de imágenes es el denominado “efecto sal y pimienta”, caracterizado por la presencia de

píxeles aislados con asignaciones erróneas debido a la heterogeneidad espectral del paisaje (Jensen, 1996). Para mitigar este fenómeno, se aplican técnicas de postclasificación que buscan mejorar la coherencia espacial sin modificar el modelo original. Entre ellas, el análisis de mayoría (Majority Analysis) permite reasignar la clase de un píxel en función de su vecindario, reduciendo el ruido espacial (Congalton y Green, 2009). Por su parte, el filtro sieve (Sieve Class) elimina parches de tamaño reducido, favoreciendo la continuidad espacial de unidades mayores (Foody y Mathur, 2004).

No obstante, estas técnicas implican un trade-off metodológico, ya que, si bien mejoran la legibilidad y reducen errores, pueden eliminar elementos de pequeña escala con relevancia ecológica, como humedales o cuerpos de agua someros. Por ello, su aplicación requiere un ajuste cuidadoso de parámetros en función de la escala y los objetivos del estudio.

En este sentido, la validación cuantitativa y el refinamiento espacial deben entenderse como un proceso integrado, orientado a garantizar tanto la confiabilidad estadística como la coherencia espacial del producto final. Este enfoque resulta esencial para su aplicación en monitoreo ambiental, planificación territorial y evaluación de políticas públicas.

Por lo tanto, el objetivo de este estudio es validar, a escala local, una clasificación supervisada de coberturas de la tierra previamente desarrollada (Arce Cendoya et al., 2024), y aplicar procedimientos de refinamiento espacial que permitan mejorar su precisión y coherencia. Asimismo, se busca analizar el efecto de los filtros de postclasificación sobre el producto resultante, contribuyendo a una mejor comprensión de las implicancias metodológicas en contextos de paisajes complejos.

Área de estudio

El partido de Puan, ubicado en el sudoeste de la provincia de Buenos Aires dentro de la Región Pampeana Austral (Figura 1), abarca aproximadamente 6.835 km² y presenta un paisaje caracterizado por planicies y lomadas suaves desarrolladas sobre mantos loésicos y antiguas geoformas eólicas. Estas se combinan con depresiones que alojan cuerpos de agua someros, en muchos casos de carácter temporario, configurando un sistema típico del semiárido pampeano, donde lagunas, cuencas endorreicas y arreicas actúan como elementos estructurales del paisaje (Iriondo y Kröhling, 2008; Cabrera, 1976, Arce Cendoya et al., 2025). El clima presenta una transición entre condiciones templadas subhúmedas y semiáridas, con precipitaciones anuales entre 650 y 800 mm y una marcada

variabilidad interanual que favorece la alternancia de sequías y excesos hídricos.



Figura 1

Localización del partido de Puan, provincia de Buenos Aires, Argentina

Fuente: Elaborado por Arce Cendoya et al., 2024

Los suelos predominantes son Molisoles, con buen contenido de materia orgánica y estructura favorable, aunque crecientemente afectados por procesos de degradación asociados a prácticas agrícolas intensivas, como la pérdida de cobertura vegetal y el deterioro físico (Soriano, 1992, Álvarez y Steinbach, 2010). Las pendientes suaves (1–5 %) incrementan la susceptibilidad a la erosión hídrica en condiciones de baja cobertura.

La vegetación original corresponde al espinal, con pastizales y bosques abiertos de caldén (*Prosopis caldenia*), actualmente fuertemente modificados por el uso agropecuario. Persisten relictos fragmentados de monte nativo —piquillín, molle y chañar— que cumplen funciones ecológicas clave (Gaspari y González, 2021). Los cuerpos de agua temporarios, por su parte, actúan como hábitats de especies indicadoras y cumplen un rol relevante en la dinámica ecosistémica (Kandus y Minotti, 2010).

El sistema productivo dominante es agropecuario, basado en agricultura extensiva (trigo, maíz y girasol) y ganadería bovina. Entre las principales problemáticas ambientales se destacan la erosión, la fragmentación del monte nativo, la contaminación por agroquímicos y la variabilidad hidrológica (Bianchi et al., 2015, Viglizzo et al., 2019).

Metodología

La estrategia metodológica se estructuró en tres etapas secuenciales: clasificación, validación externa y postprocesamiento, en concordancia con los estándares internacionales de evaluación de productos temáticos derivados del procesamiento digital de imágenes (Congalton y Green, 2009). Esta organización no solo responde a una lógica operativa, sino también a un principio epistemológico según el cual toda clasificación supervisada constituye una hipótesis de interpretación que debe ser verificada y refinada mediante evidencias externas. En este sentido, la validación y el postprocesamiento se consideran instancias fundamentales para garantizar la confiabilidad del producto final (Figura 3).

El proceso se basó en una clasificación preexistente de coberturas del partido de Puan (Arce Cendoya et al., 2024), elaborada con imágenes Sentinel-2 MSI (10 m) mediante el algoritmo Random Forest, reconocido por su robustez y precisión en contextos heterogéneos (Breiman, 2001). Asimismo, se incorporaron índices espectrales derivados de bandas ópticas para resaltar propiedades biofísicas específicas (Figura 2).

Índice espectral	Cálculo	Cálculo con S2 - A
NDVI	$\frac{NIR + RED}{NIR - RED}$	$\frac{B8 + B4}{B8 - B4}$
NDWI	$\frac{GREEN + NIR}{GREEN - NIR}$	$\frac{B3 + B8}{B3 - B8}$
BSI	$\frac{(RED + SWIR) - (NIR + BLUE)}{(RED + SWIR) + (NIR + BLUE)}$	$\frac{(B4 + B5) - (B8 + B2)}{(B4 + B5) + (B8 + B2)}$
SAVI	$\frac{(NIR - RED)}{(NIR + RED + L) \cdot 1 + L}$	$\frac{(B8 - B4)}{(B8 + B4 + 0.5) \cdot 1 + 0.5}$

Figura 2**Índices Espectrales**

Fuente: obtenido de Arce Cendoya et al., 2024

Se emplearon composiciones de color verdadero y falso color como herramienta de interpretación visual, facilitando la selección de regiones de entrenamiento (ROI) y la discriminación espectral entre clases. Asimismo, se incorporó información de relevamientos de campo, que aportó datos empíricos para validar la interpretación y asegurar la representatividad de las muestras. La integración del análisis visual multiespectral y la verificación in situ fortaleció la consistencia temática del procedimiento. Como resultado, se obtuvo una capa de coberturas de la tierra a 10 m de resolución, utilizada como insumo base para las etapas posteriores (Arce Cendoya et al., 2024).

La segunda etapa consistió en la evaluación de la precisión mediante la comparación con el producto global ESA WorldCover, desarrollado a partir de imágenes Sentinel-1 y Sentinel-2 con igual resolución espacial (Zanaga et al., 2022). Este producto fue seleccionado por su consistencia metodológica y su valor como referencia para clasificaciones locales, permitiendo además analizar la escalabilidad del modelo en el sudoeste bonaerense (Figura 3).




Figura 3
Clasificación de coberturas de la tierra de ESA WorldCover
Fuente: obtenido de Zanaga et al., 2022

Para garantizar la comparabilidad, se estableció una correspondencia temática entre leyendas (Tabla I). Posteriormente, se implementó un muestreo aleatorio estratificado con 100 puntos por clase, asegurando la representación de todas las categorías. Este enfoque, basado en una asignación igualitaria, permitió otorgar el mismo peso a cada clase en la evaluación, independientemente de su superficie relativa, evitando la subrepresentación de coberturas minoritarias y favoreciendo la robustez de las métricas de precisión (Mora, 2000).

Tabla I
Correspondencia de coberturas de la tierra entre ambas clasificaciones

Cobertura de la tierra	Código de clasificación RF (Arce Cendoya et al., 2024)	Cobertura de la tierra	Código de ESA WorldCover
Cuerpo de agua	1	Masa de agua permanente	80
Monte	2	Arbusto/Matorral	20
Humedal	3	Humeral herbáceo	90
Tierra para cultivo	4	Tierra de cultivo	40
Salinas	5	Humeral herbáceo	90
Pastizal	6	Pradera	30
Planta urbana	7	Urbanizado	50

Fuente: elaborado por Arce Cendoya, Barragán y Geraldí, 2026

La Tabla I presenta la correspondencia entre las categorías definidas por Arce Cendoya et al. (2024) y las clases de ESA WorldCover. La clase cuerpos de agua incluye masas superficiales como lagos, embalses y cursos fluviales, mientras que monte comprende vegetación leñosa de baja altura (<5 m), tanto perenne como caducifolia. Los humedales y salinas se asocian a ambientes con inundación permanente o recurrente, con distintos grados de salinidad. Las tierras de cultivo corresponden a cultivos herbáceos anuales, y el pastizal a vegetación herbácea natural sin estructura leñosa. Por su parte, la planta urbana abarca áreas edificadas e infraestructuras asociadas.

Para cada punto de validación se extrajeron las clases de ambas fuentes, permitiendo construir una matriz de confusión y cuantificar la consistencia entre productos, aunque sin garantizar una representación exacta del estado real del paisaje (Congalton y Green, 2009).

A partir de dicha matriz, se calcularon las siguientes métricas:

$$AO = \frac{\sum_{ii} x_{ii}}{N} \quad (1)$$

donde OA es la precisión global y los aciertos en la diagonal principal (1).

$$PA_i = \frac{x_{ii}}{\sum_{j=1}^n x_{ij}} ; UA_i = \frac{x_{ii}}{\sum_{j=1}^n x_{ji}} \quad (2)$$

donde PAi corresponde a la precisión del productor (errores de omisión) y UAi a la precisión del usuario (errores de comisión) (2).

$$K = \frac{p_o - p_e}{1 - p_e} \quad (3)$$

donde κ representa el coeficiente Kappa (3) (Landis y Koch, 1977), indicador robusto del grado de concordancia ajustado al azar, po es la proporción de coincidencias observadas y pe la proporción de coincidencias esperadas al azar. Los resultados del coeficiente pueden presentar los siguientes valores (Tabla II):

Tabla II

Rango de valores que puede adoptar el coeficiente de Kappa

Valor de k	Interpretación
< 0	Sin acuerdo
$0 - 0.20$	Acuerdo leve
$0.21 - 0.40$	Acuerdo moderado
$0.41 - 0.60$	Acuerdo aceptable
$0.61 - 0.80$	Acuerdo sustancial
$0.81 - 1.00$	Acuerdo casi perfecto

Fuente: extraído de Landis y Koch, 1977

Esta validación permitió cuantificar el nivel de acuerdo entre la clasificación local y la referencia global, aportando un respaldo

objetivo a la fiabilidad del modelo y a la coherencia espacial de los resultados obtenidos.

La etapa final tuvo como propósito optimizar la coherencia espacial del producto y mejorar su legibilidad cartográfica mediante técnicas de postclasificación. Las clasificaciones supervisadas suelen presentar el denominado “efecto sal y pimienta”, resultado de la variabilidad espectral intraclase y del análisis píxel a píxel.

Para mitigar los errores asociados a la asignación de clases a nivel de píxel y mejorar la coherencia espacial del producto clasificado, se aplicaron dos procedimientos de refinamiento. En primer lugar, se implementó un análisis de mayoría (Majority Analysis), técnica que reasigna la clase de cada píxel en función de la categoría predominante dentro de un vecindario definido. En este estudio se empleó una ventana de 5×5 píxeles, lo cual implica trabajar con un vecindario de 25 píxeles. Este enfoque permite generalizar la escena, reducir la presencia de parches pequeños o ruido de clasificación, y favorecer la consolidación de unidades de paisaje más extensas (Lillesand et al., 2015).

Por otro lado, se aplicó el filtro Sieve Class, este identifica componentes conectados —grupos de píxeles contiguos que comparten la misma clase— y elimina aquellos cuya superficie se encuentra por debajo de un umbral mínimo definido. Para ello, emplea conectividad de 8 vecinos (incluyendo diagonales), y los píxeles pertenecientes a estos fragmentos menores son reasignados a la clase dominante en su entorno inmediato (Richards y Jia, 2006, Jensen, 1996).

En conjunto, las tres etapas —clasificación inicial, validación externa y postprocesamiento— conforman un flujo metodológico coherente y replicable (Figura 4), que busca garantizar la precisión, fiabilidad y utilidad analítica de capa de coberturas de la tierra del partido de Puan. Este enfoque integral permite no solo cuantificar la calidad del producto obtenido, sino también consolidar una base metodológica sólida para futuros estudios de dinámica espacio-temporal de coberturas de la tierra.


**Figura 4**

Diagrama metodológico

Fuente: elaborado por Arce Cendoya, Barragán y Geraldí, 2026

Resultados

El producto de coberturas de la tierra muestra una clara predominancia del pastizal, que ocupa aproximadamente el 72 % del área de estudio, en concordancia con el perfil ganadero regional y la escasa cobertura vegetal posterior a las cosechas. Las tierras de cultivo presentan una baja representación (1,7 %). La planta urbana alcanza el 6 %, aunque incluye posibles confusiones con suelo desnudo debido a la heterogeneidad espectral. El monte ocupa el 13,7 %, con distribución discontinua en sectores marginales, mientras que los cuerpos de agua (0,8 %) y las salinas (0,2 %) presentan escasa presencia (Arce Cendoya et al., 2024). (Figura 4).




Figura 5
Productos informativos obtenidos en cada etapa del procedimiento aplicado
Fuente: elaborado por Arce Cendoya, Barragán y Geraldí, 2026

En conjunto, el patrón espacial evidencia la dominancia de coberturas herbáceas —incluyendo pastizales y áreas agrícolas—, complementadas por montes y cuerpos de agua distribuidos de forma dispersa.

En cuanto a la validación externa mediante el producto de la ESA, se obtuvo una precisión global (OA) de 0,61 y un índice Kappa de 0,54 (Tabla III), lo que indica una concordancia moderada y aceptable entre ambas fuentes. En particular, las clases asociadas a coberturas vegetales presentaron los valores más bajos de concordancia: humedal (42 %) y monte (51 %), evidenciando una elevada confusión espectral entre estas categorías. Este comportamiento es consistente con la similitud biofísica y estructural de dichas coberturas, así como con la presencia de transiciones graduales y mosaicos espaciales que dificultan su separación. En contraste, las clases con rasgos espectrales más definidos mostraron mejores desempeños, como pastizales, cuerpos de agua, y planta urbana (60–64 %). Los errores de omisión y comisión se distribuyeron de manera relativamente equilibrada entre las clases con mayor confusión, con valores mayormente concentrados en el rango 45–55 %, lo que indica limitaciones tanto en la identificación completa de las coberturas como en la asignación correcta de los píxeles clasificados.

Tabla III

Matriz de confusión entre clases de clasificación inicial y ESA WorldCover

Clase ↓ \ Clase →	Cuerpos de agua	Monte	Humedal	Tierras para cultivo	Salinas	Pastizal	Planta urbana	Total referencia	Exactitud del usuario (%)
Cuerpos de agua	60	7	15	6	9	3	0	100	51.7
Monte	15	58	10	6	5	6	0	100	55.2
Humedal	18	6	48	7	17	4	0	100	42.9
Tierras cultivo	2	18	8	55	4	13	0	100	60.4
Salinas	18	3	26	3	45	5	0	100	54.2
Pastizal	3	12	4	14	3	64	0	100	67.4
Planta urbana	0	1	1	0	0	0	98	100	100
Total clasificada	116	105	112	91	83	95	98	700	
Exactitud del productor (%)	60	58	48	55	45	64	98		

Fuente: elaborado por Arce Cendoya, Barragán y Geraldí

Durante la etapa de postclasificación se aplicaron los filtros Majority Analysis y Sieve Class, con el objetivo de reducir el ruido espectral, eliminar píxeles aislados y mejorar la coherencia espacial de las unidades. Este proceso produjo cambios visuales evidentes: las clases se tornan más continuas y homogéneas, y se redujo significativamente la presencia de áreas sin clasificación (Figura 5).

A nivel cuantitativo, se registraron modificaciones en la superficie de varias clases, especialmente en tierras de cultivo, cuerpos de agua y pastizales, que habían presentado los mayores errores de omisión y comisión en la clasificación inicial. Estas clases mejoraron notablemente sus métricas de precisión, lo que se tradujo en una mayor correspondencia con el patrón de coberturas esperado.

Tabla IV

Matriz de confusión entre clases de filtro Majority Analysis y ESA WorldCover

Clase ↓ \ Clase →	Cuerpos de agua	Monte	Humedal	Tierras para cultivo	Salinas	Pastizal	Planta urbana	Total referencia	Exactitud del usuario (%)
Cuerpos de agua	76	4	8	2	7	3	0	100	72.4
Monte	6	82	3	6	1	2	0	100	76.6
Humedal	8	4	75	2	7	4	0	100	75
Tierras cultivo	2	8	3	81	1	5	0	100	82.7
Salinas	11	3	8	3	73	2	0	100	81.1
Pastizal	2	5	2	4	1	86	0	100	84.3
Planta urbana	0	1	1	0	0	0	98	100	100
Total clasificada	105	107	100	98	90	102	98	700	
Exactitud del productor (%)	76	82	75	81	73	86	98		

Fuente: elaborado por Arce Cendoya, Barragán y Geraldi

La precisión global y el índice Kappa aumentaron de manera sustancial. La precisión global y el coeficiente de Kappa resultante de la validación entre clases de filtro Majority Analysis y ESA WorldCover (Tabla IV) es de 0,81 y 0,78 respectivamente. Mientras, que esos mismos parámetros para la comparación entre clases de filtro Sieve Class y ESA WorldCover (Tabla V) muestran valores de 0,82 para la precisión global y un coeficiente de Kappa de 0,79, lo que indica una mejora significativa en la fiabilidad del producto informativo final. Asimismo, los errores de omisión y comisión disminuyeron de forma generalizada, evidenciando una mayor estabilidad temática del conjunto de clases.

Tabla V

Matriz de confusión entre clases de filtro Sieve Class y ESA WorldCover

Clase ↓ \ Clase →	Cuerpos de agua	Monte	Humedal	Tierras para cultivo	Salinas	Pastizal	Planta urbana	Total referencia	Exactitud del usuario (%)
Cuerpos de agua	81	4	5	2	5	3	0	100	75.7
Monte	4	83	3	6	1	3	0	100	74.8
Humedal	7	3	76	2	6	6	0	100	80
Tierras cultivo	2	11	3	78	1	5	0	100	81.3
Salinas	11	3	6	3	75	2	0	100	84.3
Pastizal	2	7	2	5	1	83	0	100	81.4
Planta urbana	0	0	0	0	0	0	100	100	100
Total clasificada	107	111	95	96	89	102	100	700	
Exactitud del productor (%)	81	83	76	78	75	83	100		

elaborado por Arce Cendoya, Barragán y Geraldi

No obstante, ciertas coberturas mantuvieron errores persistentes, como los humedales y las salinas, cuyas variaciones estacionales y alta sensibilidad a los pulsos de sequía o precipitación dificultan su identificación precisa. En el caso del monte, las confusiones residuales se atribuyen a su similitud espectral con los pastizales y su baja densidad foliar en determinados sectores. La comparación de ambas etapas evidencia una mejora significativa en todos los indicadores de desempeño. La precisión del usuario, la precisión del productor, la precisión global y el coeficiente de Kappa aumentaron de valores medios (50–60 %) a niveles superiores (70–80 %) tras la aplicación de los filtros (Figura 6).

El proceso de postclasificación contribuyó además a reducir la sobreclasificación y subclasificación, logrando una redistribución más uniforme de los píxeles y una homogeneización de la respuesta espectral intraclass. En consecuencia, se observa una eliminación del ruido espectral y una mayor coherencia espacial entre unidades contiguas, aspectos que fortalecen la consistencia temática del producto final.




Figura 6
Comparación de métricas estadísticas para los tres productos generados.
Fuente: Elaborado por Arce Cendoya, Barragán y Geraldí

En términos generales y particulares, las clases de cobertura de la tierra del área de estudio muestran una alta concordancia espacial con el producto ESA, especialmente en las coberturas dominantes como pastizales y monte. Las principales diferencias se observan en los límites de parcelas agrícolas y en cuerpos de agua de pequeña extensión, los cuales tienden a ser omitidos o erróneamente clasificados debido a la resolución espacial de la imagen producto de su reducido tamaño respecto al píxel.

Las características locales del paisaje, como el relieve llano y baja energía, la heterogeneidad derivada del modelo productivo agropecuario y la variabilidad en la humedad del suelo, influyen directamente en la precisión del modelo. En particular, los sectores de mayor humedad o con cobertura mixta presentan confusiones espectrales más marcadas, lo que explica la concentración de errores en esas zonas.

Discusión

Los resultados evidencian que la metodología aplicada permitió alcanzar los objetivos propuestos, logrando una discriminación

consistente de las coberturas de la tierra. La clasificación inicial presentó una precisión global (OA) de 0,61 y un coeficiente Kappa de 0,54, indicando una concordancia moderada con el producto ESA WorldCover. Tras la aplicación de filtros de postclasificación (Majority Analysis y Sieve Class), estos indicadores aumentaron hasta 0,81–0,82 en OA y 0,78–0,79 en Kappa. Este incremento —de aproximadamente 20 puntos porcentuales en OA y 0,25 en Kappa— confirma la robustez del enfoque metodológico y su coherencia con los estándares de evaluación de precisión propuestos por Congalton y Green (2009), Olofsson et al. (2014) y Belgiu y Drăguț (2016), quienes destacan el uso de matrices de confusión y métricas derivadas para evaluar la confiabilidad temática.

En relación con estudios previos, el área analizada presenta una clara predominancia de pastizales (72 %), seguida por monte (13,7 %) y una baja proporción de tierras de cultivo (1,7 %). Esta configuración refleja un sistema agropecuario extensivo con mosaicos productivos y transiciones graduales entre coberturas, en línea con procesos de intensificación y reorganización territorial documentados por Barrantes Sotela y Sandoval Murillo (2016). No obstante, la fecha de adquisición de la imagen —posiblemente posterior a la cosecha— habría influido en la subrepresentación espectral de cultivos, cuya exactitud inicial fue del 60 %, evidenciando confusión con pastizales. Este comportamiento coincide con lo señalado por Bie et al. (2023) respecto a la variabilidad regional en la exactitud de productos de cobertura, incluso a resoluciones de 10 m.

La evaluación de precisión mostró diferencias significativas entre clases al comparar el producto local con el global. Las clases con firmas espectrales contrastantes, como cuerpos de agua (0,8 %) y planta urbana (6 %), presentaron mayor concordancia, mientras que coberturas vegetales similares —pastizales, monte y tierras de cultivo— registraron mayores errores de omisión y comisión. En particular, el monte alcanzó concordancias cercanas al 45 % y los humedales alrededor del 55 %, reflejando confusión espectral y transiciones graduales. Estos resultados coinciden con Hirayama et al. (2019), Li et al. (2023) y Bie et al. (2023), quienes atribuyen estas limitaciones a la heterogeneidad intrapíxel y a la similitud biofísica entre coberturas.

En cuanto al procesamiento, si bien la literatura reciente resalta el potencial de modelos de deep learning y enfoques multimodales (Zhao et al., 2022, Zhang et al., 2024, Irfán et al., 2025), los resultados obtenidos con Random Forest demuestran que algoritmos robustos continúan siendo eficaces cuando se combinan con estrategias adecuadas de muestreo y postprocesamiento. El aumento del coeficiente Kappa de 0,54 a 0,79 tras la aplicación de filtros espaciales sugiere que el desacuerdo inicial no respondía únicamente a

limitaciones del clasificador, sino también a la independencia espacial del enfoque píxel a píxel, en concordancia con Li et al. (2023).

El efecto “sal y pimienta”, característico de clasificaciones píxel a píxel, se evidenció en la etapa inicial a través de una textura heterogénea y una concordancia moderada. La mejora posterior, con valores de OA superiores a 0,80, constituye evidencia del impacto de este fenómeno. Tal como señalan Hirayama et al. (2019), Karakuş et al. (2017) y Yulianto et al. (2021), la clasificación independiente de cada píxel genera incoherencias espaciales que afectan tanto la interpretación visual como las métricas de exactitud, situación que fue parcialmente corregida mediante la regularización espacial.

No obstante, la aplicación de filtros implicó un trade-off relevante. Aunque se redujeron los errores globales, persistieron limitaciones en clases minoritarias como salinas y humedales, cuya baja representación espacial las hace vulnerables a la fusión o eliminación de parches pequeños. Este comportamiento coincide con Šiljeg et al. (2022) y Sun et al. (2024), quienes advierten sobre la pérdida potencial de información local asociada al filtrado espacial, indicando que la mejora en coherencia global no necesariamente se traduce en una mejor detección de elementos de pequeña escala.

El muestreo aleatorio estratificado resultó clave para la estabilidad del modelo. Dado que el pastizal domina el 72 % del área, un muestreo simple habría introducido sesgos hacia esta clase. La estrategia adoptada permitió garantizar la representación de coberturas minoritarias, contribuyendo a que la tierra de cultivo alcanzara una exactitud cercana al 48 % incluso en la clasificación inicial. Este resultado respalda lo planteado por Congalton y Green (2009), Olofsson et al. (2014) y Foody (2002) sobre la importancia del diseño muestral en la evaluación de precisión.

En cuanto al uso de ESA WorldCover como referencia, los valores obtenidos deben interpretarse en su contexto. Mientras el producto global reporta precisiones entre 0.74 y 0.77 a escala planetaria (Zanaga et al., 2022, Xu et al., 2024), la concordancia inicial local fue inferior (0,61), evidenciando variabilidad regional. Sin embargo, tras el postprocesamiento, los valores superaron 0,80, alcanzando niveles comparables o superiores a los promedios globales. Este resultado confirma lo señalado por Hao et al. (2023) y Bie et al. (2023), donde las métricas globales tienden a ocultar variaciones locales significativas, especialmente en paisajes heterogéneos.

Si bien ESA WorldCover constituye un producto global ampliamente validado y adecuado para comparaciones temáticas a gran escala, existen alternativas regionales que podrían aportar información complementaria para futuras evaluaciones. Entre ellas se destacan iniciativas como MapBiomass (Souza et al., 2020) y el Mapa Nacional de Cultivos (De Abelleira et al., 2025), cuyos enfoques se

orientan a escalas y objetivos específicos del contexto sudamericano y argentino. No obstante, estos productos presentan diferencias en su estructura temática, alcance temporal y finalidad cartográfica respecto del producto analizado, por lo que no fueron incorporados en la presente evaluación. Su utilización conjunta constituye una línea de trabajo futura que permitiría profundizar la comparación entre clasificaciones locales, regionales y globales.

Asimismo, las discrepancias en límites parcelarios y cuerpos de agua de pequeña extensión corroboran lo planteado por Ban (2015) y Xu et al. (2024) respecto a la influencia de la resolución espacial y las diferencias en definiciones temáticas. Elementos cercanos al tamaño del píxel (10 m) presentan mayor probabilidad de mezcla espectral, generando errores en comparaciones píxel a píxel.

En este marco, los resultados confirman que los productos globales constituyen insumos valiosos a gran escala, pero requieren validación a nivel local. La mejora alcanzada tras la calibración y regularización espacial demuestra que es posible obtener desempeños comparables o superiores a los promedios globales. En este contexto, el filtro Majority Analysis se destaca como la estrategia de postclasificación más eficiente, al reducir el ruido espacial sin alterar significativamente la estructura del paisaje, favoreciendo la coherencia temática y manteniendo un equilibrio adecuado entre homogeneización y preservación de patrones relevantes.

Reflexión final

La clasificación inicial, basada en imágenes Sentinel-2 y el algoritmo Random Forest, permitió generar una representación detallada del paisaje mediante la integración de índices espectrales (NDVI, NDWI, BSI, SAVI) y composiciones en color verdadero y falso color. Este enfoque facilitó la discriminación de las principales coberturas de la tierra —pastizales, tierras de cultivo, cuerpos de agua, humedales y montes—, evidenciando la heterogeneidad del área de estudio. La elección de Random Forest resultó adecuada, dado su desempeño robusto frente al ruido y su capacidad para manejar múltiples variables predictoras.

La clasificación reprodujo de manera consistente la estructura territorial del partido de Puan, caracterizada por la dominancia de coberturas herbáceas y un uso agropecuario extensivo. No obstante, la validación frente a ESA WorldCover evidenció concordancias moderadas, especialmente en clases con alta heterogeneidad espectral, fragmentación espacial y variabilidad temporal. Este resultado refleja tanto limitaciones del enfoque píxel a píxel como la complejidad inherente a paisajes semiáridos con transiciones graduales y mosaicos productivos.

La mejora sustancial de las métricas de precisión tras la aplicación de filtros de postclasificación indica que parte del desacuerdo inicial se asociaba al ruido espacial. El aumento de la precisión global y del coeficiente Kappa hacia niveles de acuerdo sustancial evidencia el rol del postprocesamiento como mecanismo de regularización espacial, capaz de generar representaciones más coherentes del paisaje. Sin embargo, esta mejora cuantitativa no implica necesariamente una representación más precisa de todos los componentes, especialmente aquellos de pequeña extensión o alto valor ecológico.

En este sentido, se confirma la existencia de un trade-off entre homogeneización y conservación del detalle local. Técnicas como Majority Analysis y Sieve Class mejoran la coherencia temática y la legibilidad, pero tienden a simplificar la estructura espacial, afectando la detección de parches pequeños como humedales temporarios o cuerpos de agua someros.

Finalmente, la comparación con ESA WorldCover permite relativizar el uso de productos globales como referencia. Si bien presentan alta precisión a escala planetaria, su desempeño varía regionalmente. Por ello, el acuerdo entre clasificaciones no debe interpretarse como validación absoluta, sino como consistencia entre representaciones construidas bajo diferentes marcos conceptuales. En conjunto, el estudio resalta la importancia de integrar métricas de precisión, coherencia espacial y conocimiento del paisaje, y propone un enfoque replicable para el análisis de coberturas en contextos ambientalmente complejos.

Financiamiento

El trabajo pertenece al Proyecto de Investigación PGI: "Modelado, Resiliencia Territorial y Gestión Ambiental Sustentable mediante Tecnologías de Información Geográfica: Enfoques Comparativos para la planificación y Gestión". Código de identificación 24/G101.

Referencias Bibliográficas

- Álvarez, R., y Steinbach, H. S. (2010). *Degradación física de los suelos de la región pampeana*. *Ciencia del Suelo*, 28(1), 11–20.
- Arce Cendoya, S., Barragán, F. G., y Geraldí, A. M. (2024). Análisis de la cobertura del suelo a partir del uso del algoritmo Random Forest. *FACENA*, 34(2), 270–289. <https://doi.org/10.30972/fac.3427776>
- Arce Cendoya, S., Barragán, F. G., y Geraldí, A. M. (2025). Variabilidad espacio-temporal de cuerpos de agua someros en un área de la región pampeana. *FACENA*, 35(1), 19–41. <https://doi.org/10.30972/fac.3517770>
- Ban, Y., Gong, P., y Giri, C. (2015). Global land cover mapping using Earth observation satellite data: Recent progresses and challenges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 1–6. <https://doi.org/10.1016/j.isprsjprs.2015.01.001>
- Barrantes Sotela, M., y Sandoval Murillo, D. (2016). Análisis de cobertura del suelo en los cantones de Upala, Guatuso y Los Chiles.
- Belgiu, M., y Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bianchi, A. R., Cravero, S. A., y García, N. O. (2015). *Climatología del sudoeste bonaerense*. INTA.
- Bie, J., Luo, Z., y Lu, D. (2023). Accuracy performance of three 10-m global land cover products around 2020 in an arid region of northwestern China. *IEEE Access*, 11, 133215–133228. <https://doi.org/10.1109/ACCESS.2023.3336733>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cabrera, A. L. (1976). *Regiones fitogeográficas argentinas*. ACME.
- Congalton, R. G., y Green, K. (2009). *Assessing the accuracy of remotely sensed data: Principles and practices (2nd ed.)*. CRC Press.
- De Abelleira, D., Iturralde Elortegui, M. R. M., Zelaya, D. K., Portillo, J. E., Volante, J. N., Franzoni, A., Lopez Morillo Barros, C. S., Goytia, S. Y., Murray, F., Santillan, J. L., Berriolo, M. J., Lanceta Pereyra, M. M., Scavone, A. S., Continelli, N., Gerlero, G. D., Reinaldi, J. A., Lopez Juane, P. A., Gomez, D. G., Krapovickas, S. y Vitale, J. P. (1 de noviembre de 2025). *Mapa Nacional de Cultivos campaña 2024/2025 (Versión 1, Publicación N.º 7) [Informe técnico]*. Instituto Nacional

- de Tecnología Agropecuaria (INTA). <http://hdl.handle.net/20.500.12123/24705>
- Di Gregorio, A. (2005). *Land cover classification system: classification concepts and user manual: LCCS (Vol. 8)*. Food y Agriculture Org.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Foody, G. M., y Mathur, A. (2004). Toward intelligent training of supervised image classifications: Directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93(1–2), 107–117. <https://doi.org/10.1016/j.rse.2004.06.017>
- Gaspari, G., y González, L. (2021). *Cuenca Forestal Puan–Villarino–Patagones: Diagnóstico ambiental y socioeconómico* [Informe técnico]. RedFor – Innovat.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hao, X., Qiu, Y., Jia, G., Menenti, M., Ma, J., y Jiang, Z. (2023). Evaluation of Global Land Use–Land Cover Data Products in Guangxi, China. *Remote Sensing*, 15(5), 1291. <https://doi.org/10.3390/rs15051291>
- Hirayama, H., Sharma, R. C., Tomita, M., y Hara, K. (2019). Evaluating multiple classifier system for the reduction of salt-and-pepper noise in the classification of very-high-resolution satellite images. *International Journal of Remote Sensing*, 40(3), 1105–1124. <https://doi.org/10.1080/01431161.2018.1528414>
- Irfan, A., Li, Y., E, X., y Sun, G. (2025). Land Use and Land Cover Classification with Deep Learning-Based Fusion of SAR and Optical Data. *Remote Sensing*, 17(7), 1298. <https://doi.org/10.3390/rs17071298>
- Iriondo, M., y Kröhling, D. (2008). *El loess en la región pampeana*. Universidad Nacional del Litoral.

- Jensen, J. R. (1996). *Introductory digital image processing: A remote sensing perspective (4th ed.)*. Pearson.
- Kandus, P., y Minotti, P. (2010). Los humedales de la llanura pampeana: Caracterización y estado de conservación. *Ecología Austral*, 20, 89–108.
- Karakuş, P., Karabork, H., y Kaya, Ş. (2017). A comparison of the classification accuracies in determining the land cover using pixel-based and object-based classification algorithms. *Turkish Journal of Geosciences*, 3(2), 45–56.
- Landis, J. R., y Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174. <https://doi.org/10.2307/2529310>
- Li, R., Gao, X., Shi, F., y Zhang, H. (2023). Scale effect of land cover classification from multi-resolution satellite remote sensing data. *Sensors*, 23(13), 6136. <https://doi.org/10.3390/s23136136>
- Lillesand, T., Kiefer, R. W., y Chipman, J. (2015). *Remote sensing and image interpretation*. Wiley.
- Liu, B., Du, S., y Zhang, X. (2020). Land cover classification using convolutional neural network with remote sensing data and digital surface model. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2020, 183–190. <https://doi.org/10.5194/isprs-annals-V-3-2020-39-2020>
- Marceau, D. J. (1999). The scale issue in the social and natural sciences. *Canadian Journal of Remote Sensing*, 25(4), 347–356. <https://doi.org/10.1080/07038992.1999.10874736>
- Mora, E. (2000). Algunas consideraciones sobre muestreo. *Revista Geográfica Venezolana*, 41(1), 31–46.
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., y Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Phiri, D., y Morgenroth, J. (2017). Developments in Landsat Land Cover Classification Methods: A Review. *Remote Sensing*, 9(9), 967. <https://doi.org/10.3390/rs9090967>
- Posada, E., y Salvatierra, H. C. (2016). Análisis comparativo de las metodologías de los sistemas de clasificación de la cobertura de la Tierra LCCS y CORINE, para mapeo de coberturas terrestres. *Revista Geográfica*, (157), 135-159

- Richards, J. A., y Jia, X. (2006). *Remote sensing digital image analysis: An introduction* (4th ed.). Springer.
- Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Šiljeg, A., Marić, I., Cavrić, B., & Barada, M. (2022). Object-based land cover classification using machine learning algorithms. *Remote Sensing*, 14(3), 541. <https://doi.org/10.3390/rs14030541>
- Soriano, A. (1992). Río de la Plata grasslands. En R. T. Coupland (Ed.), *Natural grasslands: Introduction and Western Hemisphere* (pp. 367–407). Elsevier.
- Souza, C. M., Jr., Shimbo, J. Z., Rosa, M. R., Parente, L. L., Alencar, A. A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., Ferreira, L. G., Souza-Filho, P. W. M., de Oliveira, S. W., Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E. y Weber, E. J. (2020). Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. *Remote Sensing*, 12(17), Artículo 2735. <https://doi.org/10.3390/rs12172735>
- Sun, Z., Li, X., Zhang, H., & Liu, Y. (2024). Deep learning-based approaches for land use and land cover classification: A review. *Remote Sensing of Environment*, 298, 113789. <https://doi.org/10.1016/j.rse.2023.113789>
- Turner, M. G. (1989). Landscape ecology: The effect of pattern on process. *Annual Review of Ecology and Systematics*, 20, 171–197. <https://doi.org/10.1146/annurev.es.20.110189.001131>
- Ullah, A., Akbar, M., Luo, Q., Khan, A. J., Dees, M., & Ali, I. (2017). Evaluating the impact of classification algorithms and spatial resolution on the accuracy of land cover mapping in a mountain environment in Pakistan. *Arabian Journal of Geosciences*, 10(7), 171. <https://doi.org/10.1007/s12517-017-2859-6>
- Viglizzo, E. F., Jobbágy, E. G., y Ricard, M. F. (2019). Expansión agrícola y riesgos ambientales en la Pampa seca. *Revista Ambiente y Agua*, 14(3), e2355.

- Winkler, K., Fuchs, R., Rounsevell, M. y Herold, M. (2021). Global land use changes are four times greater than previously estimated. *Nat Commun* 12, 2501. <https://doi.org/10.1038/s41467-021-22702-2>
- Wu, J. (2004). Effects of changing scale on landscape pattern analysis: Scaling relations. *Landscape Ecology*, 19, 125–138. <https://doi.org/10.1023/B:LAND.0000021711.40074.ae>
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., Allen, R. G., Anderson, M. C., Belward, A. S., Cohen, W. B., Dwyer, J., Erb, A., Gao, F., Griffiths, P., Helder, D., Hermosilla, T., Hipple, J. D., Hostert, P., Hughes, M. J., Huntington, J., Loveland, T. R., Martinuzzi, S., Maxwell, S., McCorkel, J., Melrose, R., Phinn, S. R., Scambos, T. A., Schaaf, C., Schott, J. R., Sheng, Y., Storey, J., Vermote, E., Vogelmann, J., White, J. C., Wynne, R. H., & Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote Sensing of Environment*, 225, 127–147. <https://doi.org/10.1016/j.rse.2019.02.015>
- Xu, P., Tsendbazar, N.-E., Herold, M., de Bruin, S., Koopmans, M., Birch, T., Carter, S., Fritz, S., Lesiv, M., Mazur, E., Pickens, A., Potapov, P., Stolle, F., Tyukavina, A., Van De Kerchove, R., & Zanaga, D. (2024). Comparative validation of recent 10 m-resolution global land cover maps. *Remote Sensing of Environment*, 311, 114316. <https://doi.org/10.1016/j.rse.2024.114316>
- Yulianto, F., Nugroho, G., Chulafak, A., Galdita, G., y Suwarsono, S. (2021). Improvement in the accuracy of the postclassification of land use and land cover using Landsat 8 data based on the majority of segment-based filtering approach. *The Scientific World Journal*, 2021, 6658818. <https://doi.org/10.1155/2021/6658818>
- Zanaga, D., Van De Kerchove, R., Daems, D., De Keersmaecker, W., Brockmann, C., Kirches, G., Wevers, J., Cartus, O., Santoro, M., Fritz, S., Lesiv, M., Herold, M., Tsendbazar, N.-E., Xu, P., Ramoino, F., y Arino, O. (2022). *ESA WorldCover 10 m 2021 v200*. 10.5281/zenodo
- Zhang, L., Lu, Y., Shi, R., Shen, Y., y Shao, Y. (2024). Towards interpretability lightweight semantic segmentation model for waterbody extraction in large-scale high resolution remote sensing images. *International Journal of Remote Sensing*, 45(8), 2721–2738. <https://doi.org/10.1080/01431161.2024.2334812>
- Zhao, J., Wang, L., Yang, H., Wu, P., Wang, B., Pan, C., y Wu, Y. (2022). A Land Cover Classification Method for High-Resolution Remote

Sensing Images Based on NDVI Deep Learning Fusion Network.
Remote Sensing, 14(21), 5455. <https://doi.org/10.3390/rs14215455>

AmeliCA

Disponible en:

<https://portal.amelica.org/ameli/ameli/journal/739/7395700002/7395700002.pdf>

Cómo citar el artículo

Número completo

Más información del artículo

Página de la revista en portal.amelica.org

AmeliCA

Ciencia Abierta para el Bien Común

Sebastián Arce Cendoya, Alejandra Mabel Geraldí,
Federico Gastón Barragán

**Validación cruzada y mejora de clasificación supervisada
en coberturas de la tierra del partido de Puan mediante
GEE y WorldCover**

**Cross-validation and improvement of supervised land
cover classification in the Puan district using GEE and
WorldCover**

Párrafos Geográficos

vol. 25, núm. 1, p. 61, 2026

Universidad Nacional de la Patagonia San Juan Bosco,
Argentina

parrafosgeograficos@fhcs.unp.edu.ar

ISSN: 1853-9424

ISSN-E: 1666-5783



CC BY-NC-SA 4.0 LEGAL CODE

**Licencia Creative Commons Atribución-NoComercial-
CompartirIgual 4.0 Internacional.**