

Clasificación de uso y cobertura del suelo basada en modelos de Aprendizaje de Máquina Supervisados

Beron de la Puente Federico Javier^{1,2}[0000-0003-4228-4593], Montico Anabella^{1,2}[0000-0002-4618-2992], Revollo Natalia V.^{3,4}[0000-0002-2591-9123], Gil Verónica^{1,2}[0000-0002-2824-204X] and Zapperi Paula A.^{1,2}[0000-0003-0783-1467]

¹ Departamento de Geografía y Turismo, Universidad Nacional del Sur, Bahía Blanca, Buenos Aires, Argentina

² Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina

³ Departamento de Ingeniería Eléctrica y de Computadoras, Universidad Nacional del Sur, Argentina

⁴ Instituto de Ciencias e Ingeniería de la Computación - ICIC (CONICET/UNS), Argentina

fjberon@criba.edu.ar, anabella.montico@uns.edu.ar,
nrevollo@criba.edu.ar, verogil@uns.edu.ar,
paula.zapperi@uns.edu.ar

Abstract. La obtención de información geográfica de usos y coberturas del suelo (LULC) es crucial para el monitoreo espacio-temporal de la actividad agrícola y de sus efectos sobre el ambiente. En este marco, el objetivo del trabajo fue comparar la performance de Google Earth Engine (GEE) y del complemento Semi-automatic Classification Plugin (SCP) dentro de QGIS para clasificar LULC en imágenes multiespectrales Sentinel-2. Los modelos fueron aplicados a una región del centro-sur del sistema de Ventania, en el suroeste de la provincia de Buenos Aires, Argentina y validados con información medida in situ. Los resultados indican que ambos modelos son capaces de clasificar LULC con una precisión entre 77.6 % y 97.8%, habiendo obtenido mejores resultados con GEE.

Keywords: LULC, Modelos de Aprendizaje de Máquina Supervisados, áreas agrícolas.

1 Introducción

Los usos y coberturas del suelo (LULC, por sus siglas en inglés) constituyen un factor relevante en diversos procesos ambientales dado que ejercen influencia sobre la dinámica hídrica [1, 2, 3], la pérdida de suelo fértil frente a la erosión hídrica [4, 5] y la contaminación del suelo y del agua [6, 7]. Es así que, contar con información sobre sus cambios a lo largo del tiempo y sus potenciales efectos sobre los ecosistemas y el

bienestar humano resulta fundamental para guiar los procesos de toma de decisiones y planificación territorial [8, 9]. Su relevancia se evidencia, por ejemplo, en las iniciativas de distintos países y regiones del mundo vinculadas a la creación de inventarios de los usos y coberturas del suelo como Corine Land Cover, desarrollado por Copernicus Land Monitoring Service y el National Land Cover Database (NLCD), confeccionado por el U.S. Geological Survey (USGS). En Argentina, pueden mencionarse los esfuerzos del Instituto Nacional de Tecnología Agropecuaria (INTA) para el desarrollo de mapas nacionales de cultivos desde el año 2018, a través del monitoreo de las campañas de invierno y verano para los principales cultivos en la zona núcleo de actividad agrícola [10].

En la actualidad, la obtención de información geográfica de LULC se realiza a través de imágenes multiespectrales. El surgimiento de nuevas tecnologías como computación en la nube y algoritmos de aprendizaje de máquina han permitido la reducción del tiempo de procesamiento de datos a diferentes escalas espacio-temporales. Es por esto que, el procesamiento digital de imágenes satelitales se ha transformado en una herramienta para la obtención de información precisa y actualizada para la caracterización de LULC [11, 12, 13]. Existen múltiples antecedentes de estudios que han abordado comparativamente diferentes algoritmos de clasificación pixel-base como máxima verosimilitud, random forest (RF), support vector machine [14, 15, 16, 17]. Otros proyectos han analizado y evaluado diferentes tipos de imágenes multiespectrales para la clasificación de LULC [18, 19]. Sin embargo, no se han realizado estudios que comparen herramientas para la clasificación de LULC.

En el campo del procesamiento digital de imágenes satelitales existen modelos basados en aprendizaje de máquina que pueden estar integrados en complementos en un sistema de escritorio SIG o en plataformas de cloud computing. Entre las aplicaciones SIG puede mencionarse el Semi-Automatic Classification plugin (SCP), que se emplea dentro del entorno de QGIS, y tiene como propósito ofrecer un conjunto de herramientas interrelacionadas para el procesamiento de imágenes ráster generando un flujo de trabajo automatizado y simplificado en la clasificación de la cobertura del suelo [20]. Ha sido utilizado en diversos estudios, tanto para analizar los algoritmos de clasificación disponibles [21] como en estudios aplicados [22, 23].

Frente a la necesidad del acceso y manejo a grandes volúmenes de información y herramientas de procesamiento han surgido plataformas que facilitan la realización de inventarios de LULC en grandes regiones. Una de las plataformas más utilizadas para este fin es Google Earth Engine (GEE). GEE es una plataforma para el procesamiento de las imágenes satelitales a partir de servicios de cloud computing, lo que permite acceder de manera rápida y sencilla a una gran colección de imágenes multiespectrales [24]. Su uso extendido se fundamenta en que posibilita el acceso libre y procesamiento

de grandes conjuntos de datos [25]. Esto se evidencia en los múltiples estudios en los que ha sido utilizado [26, 27].

En este contexto, el objetivo del trabajo es comparar la performance de un modelo entrenado y validado con GEE y SCP de QGis para la clasificación de LULC. En la sección siguiente, se presenta la metodología y una descripción del área de estudio. Posteriormente, se desarrollan los resultados, que incluyen el análisis de las estadísticas de las clasificaciones y los distintos mapas de LULC obtenidos, así como de las ventajas y desventajas de cada plataforma. Finalmente, se presentan las conclusiones.

2 Materiales y métodos

2.1 Área de Estudio

El área de estudio corresponde a un sector de aproximadamente 2500 km², ubicado en el centro sur del sistema de Ventania, suroeste bonaerense, entre los partidos de Tornquist, Coronel Suárez, Coronel Pringles y Bahía Blanca (Figura 1). Geomorfológicamente, existen dos grandes unidades que caracterizan a la región: la llanura, con leves contrastes topográficos y desarrollo de suelos aptos para el cultivo y el Sistema de Ventania dominado por afloramientos rocosos de menos de 1250 m s.n.m.

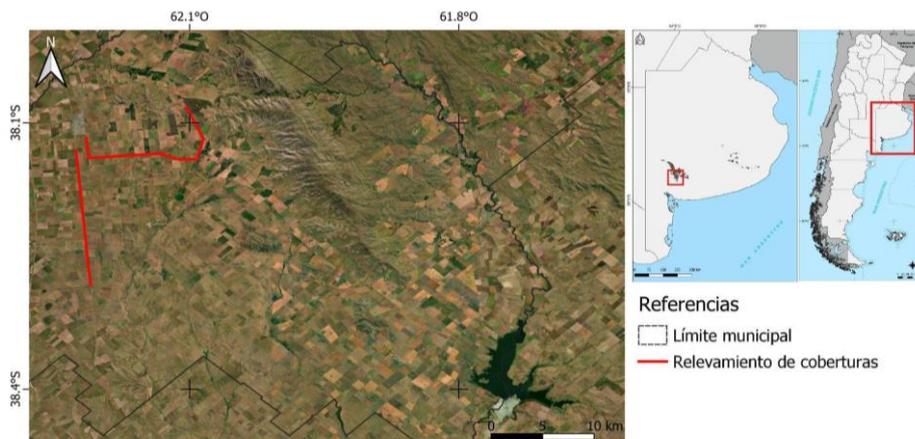


Figura 1. Área de estudio

En términos de sus características climáticas, se trata de una zona templada seca - subhúmeda que presenta una variabilidad natural temporal, estacional e interanual en las precipitaciones, expresada en la sucesión de períodos húmedos y secos [28]. Específicamente, el área serrana también posee una condición de variabilidad de las lluvias, acentuada por la altura y la orientación de las laderas [29]. De este modo, la

sucesión de períodos secos y húmedos y sus condiciones extremas impactan negativamente en el sector productivo, principalmente sobre la actividad agrícola-ganadera [30].

Los suelos característicos de la región están formados por sedimentos loésicos, lo que los hace aptos para actividades productivas [31]. Esto se ve reflejado en el perfil de la región, caracterizado por el desarrollo de agricultura (principalmente cultivo de cereales) y ganadería (cría de bovinos). Para el caso en particular del partido de Tornquist, unidad territorial que corresponde al área central del estudio, según el último censo agropecuario [32], cuenta con 414 explotaciones agropecuarias, en la mayoría de las cuales se lleva a cabo ganadería bovina. Además, el 40% de la superficie censada fue destinada a cultivos de secano, principalmente forrajeras anuales y cereales.

2.2 Metodología

En una primera etapa, se crearon dos conjuntos de datos que representan LULC, que se utilizaron para llevar a cabo la comparación entre ambas herramientas. El primero se obtuvo a partir de relevamiento en campo. Dentro de la recorrida, se identificaron parcelas por medio de instrumental GPS y fotografías georeferenciadas, reconociendo las siguientes categorías: maíz (M), pastizal (P), suelo sin cobertura (Sc), sorgo (S) y girasol (G). Por otra parte, por medio de fotointerpretación de imagen se identificaron cuerpos de agua (Ag), afloramiento rocoso (Af) y vegetación densa (Vd), que incluye tanto vegetación arbustiva como arbórea. Para el segundo dataset se unificaron las clases relacionadas a los cultivos de verano más comunes en el área de estudio: maíz, sorgo y girasol. Esto se realizó para evaluar el desempeño de ambas herramientas al reducir la complejidad de las clases objeto del mapa de LULC, teniendo en cuenta la similitud espectral entre las clases de cultivos. Las clases de este segundo dataset fueron: cuerpos de agua (Ag), agrícola (A), pastizal (P), suelo sin cobertura (Sc), afloramiento rocoso (Af) y vegetación densa (Vd).

Luego, el procedimiento específico para llevar a cabo las clasificaciones varió de acuerdo con las funcionalidades de cada plataforma. En el caso del SCP, se utilizó una única imagen Sentinel 2, con nivel de pre-procesado 2A, lo que implica que se encuentra corregida atmosféricamente y con valores de reflectancia en la parte inferior de la atmósfera (Bottom Of Atmosphere, BOA). La imagen, que corresponde al día 20 de febrero de 2023, se recortó a la región de interés (ROI) y posteriormente se crearon las áreas de entrenamiento y validación en formato polígono con los puntos obtenidos del relevamiento de campo y la fotointerpretación de la imagen. El 80% de los puntos de cada clase se emplearon para el entrenamiento del algoritmo y el 20% restante para la validación de la clasificación. Para la primera clasificación, el conjunto de

entrenamiento fue de 492 píxeles y el de validación de 125. Mientras que para la segunda, el entrenamiento contó con 586 píxeles y la validación con 167.

Por otro lado, para la clasificación supervisada en GEE se empleó la colección “COPERNICUS/S2_SR” que recoge las imágenes Sentinel 2 (S2) con nivel 2A de pre-procesado. La colección fue acotada según el porcentaje de nubosidad del 5% a partir de un recorte de la ROI y el intervalo de tiempo de adquisición de las imágenes se estableció entre el 20 de diciembre de 2022 y el 20 de febrero de 2023. Se calcularon los valores medios del mosaico de imágenes obtenido a partir de la ROI, ya que al llevar a cabo este proceso, la imagen resultante no se verá afectada por los valores atípicos [33, 34]. Ambos datasets se dividieron en dos subconjuntos de datos, en donde el 20% del total de la muestra corresponde a la información de validación y el 80% se utilizó para entrenamiento a partir de los puntos obtenidos durante el relevamiento de campo y la fotointerpretación. Quedando 152 y 646 píxeles, respectivamente para la primera clasificación, mientras que la segunda, donde las clases de cultivos se unificaron en una denominada agrícola, el dataset para validación y entrenamiento se compuso de 324 y 1360. Además, los datos para entrenar y validar el modelo fueron seleccionados de forma aleatoria y se balancearon las clases.

Para el desarrollo del modelo se utilizó el Code Editor de GEE, el cual está basado en una IDE que usa el lenguaje para la API JavaScript. El algoritmo usado para la clasificación supervisada basada en píxeles fue Random Forest (RF) (ee.Classifier.smile-RandomForest) ya que, para este tipo de clasificación, es el que permite obtener mejores resultados, especialmente en relación con la identificación de diferentes cultivos [35]. Para ambas herramientas, el RF fue utilizado con 300 árboles y las ramificaciones de acuerdo a la recomendación teórica de la raíz cuadrada del número de clases objetivo. Para la primera clasificación fue de un valor de 3 y para la segunda de 2.

En ambas plataformas se utilizaron las bandas S2 e índices espectrales que se muestran en la Tabla 1, los cuales son relevantes para la clasificación de cultivos. Una vez obtenidos los cuatro mapas de LULC, se calcularon los indicadores de la calidad temática, que permite evaluar el procedimiento realizado y su calidad en el resultado final. Por último, se compararon la precisión total (%), el coeficiente Kappa, la precisión del productor (PA%) y la del usuario (UA%).

Tabla 1. Bandas e índices espectrales empleados para la clasificación

Nombre	Significado	Fórmula	Fuente
B5	Band Roja (Red Edge 1)	-	-
B8	Banda Infrarrojo cercano (NIR)	-	-
BSI	Índice de Suelo Desnudo	$((Red+SWIR1) - (NIR+Blue)) / ((Red+SWIR1) + (NIR+Blue)) (1)$	[36]
NDBI	Índice de áreas construidas de diferencia normalizada	$(SWIR1 - NIR) / (SWIR1 + NIR) (2)$	[37]
PVR	Relación de vigor fotosintético	$(Green - Red) / (Green + Red) (3)$	[38]
NDVI	Índice de vegetación de diferencia normalizada	$(NIR - Red) / (NIR + Red) (4)$	[39]
NDWI	Índice de diferencia Normalizada agua	$(Green - NIR) / (Green + NIR) (5)$	[40]

3 Resultados y discusión

En la clasificación de ocho categorías (Tabla 2), tanto con SCP como con GEE, la mayor superficie se encuentra ocupada por el pastizal, aunque con una diferencia de 182.7 km². Otra de las diferencias más importantes se observa en la identificación del sorgo, que ocupa una mayor superficie en la clasificación obtenida con el SCP. En la figura 2 se muestran la distribución de los LULC en ambas clasificaciones.

Tabla 2. Superficies ocupadas por LULC en la clasificación de ocho categorías.

Clase LULC	SCP	GEE
Suelo	226.89	222.97
Sorgo	470.11	252.14
Maíz	205.97	274.07
Girasol	131.13	152.42
Pastizal	824.05	1006.76
Vegetación densa	69.83	79.52
Agua	26.61	27.28
Afloramiento	465.01	470.95

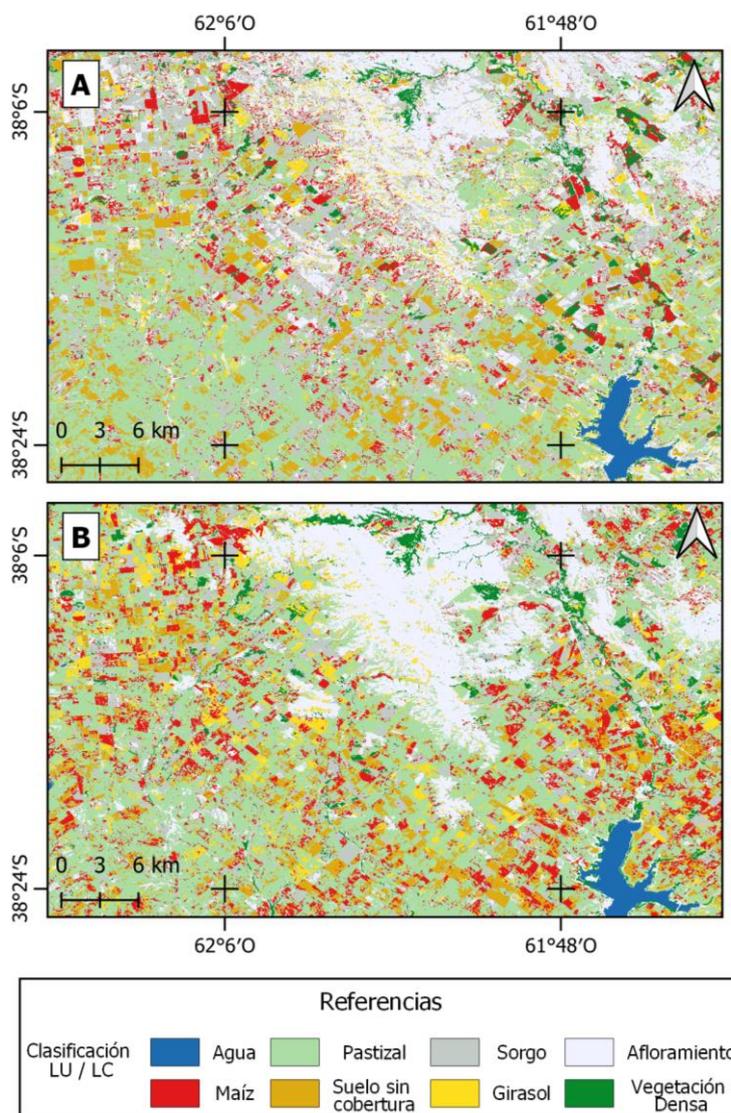


Figura 2. Mapas de LULC con ocho categorías obtenidos con A) SCP y B) GEE.

Los estadísticos de calidad de estas clasificaciones (Tabla 3) muestran que ambas obtuvieron precisiones totales aceptables, siendo superadora la de GEE, que alcanzó un valor de 93.91%. Los coeficientes Kappa fueron de 0.74 en SCP y 0.93 en GEE. En cuanto a la PA% y UA%, las performances más bajas tanto en GEE como en SCP se observaron a la hora de clasificar pastizal y sorgo, aunque fueron mejores en el caso del primero. SCP tuvo mejor performance para clasificar suelo sin cobertura mientras que, GEE fue mejor para clasificar el afloramiento y el cultivo de maíz. Con respecto al agua, en ambas plataformas se obtuvieron PA% y UA% del 100%.

Tabla 3. Estadísticos de la clasificación de 8 categorías según GEE y SCP

Estadístico	Plataforma	Sc	M	S	G	P	Vd	Af	Ag
PA (%)	SCP	100	66.67	55.56	93.33	60	93.75	60	100
	GEE	94.73	95.45	90	92.30	80.95	100	97.22	100
UA (%)	SCP	100	66.67	58.82	87.5	50	93.75	66.67	100
	GEE	85.71	100	90	100	80.95	100	97.22	100
Precisión total (%)	SCP	77.60							
	GEE	93.91							
Kappa	SCP	0.74							
	GEE	0.93							

En la clasificación de seis categorías obtenida por medio del SCP, las superficies de cada clase (Tabla 4) muestran que al unificar la categoría agrícola se observa una sobreestimación de la superficie sembrada con respecto a la clasificación de mayor complejidad, donde se diferenciaron los principales cultivos de verano de la región bajo estudio. En contraposición a lo hallado con SCP, en GEE al reducir a seis clases, se subestima la superficie agrícola. En la figura 3 se muestran la distribución de los LULC en ambas clasificaciones.

Tabla 4. Superficies ocupadas por LULC en la clasificación de seis categorías.

Clase LULC	SCP	GEE
Suelo	197.70	197.27
Agrícola	1027.93	469.6
Pastizal	615.59	1131.28
Vegetación densa	35.43	61.18
Agua	26.66	28.31
Afloramiento	516.29	600.54

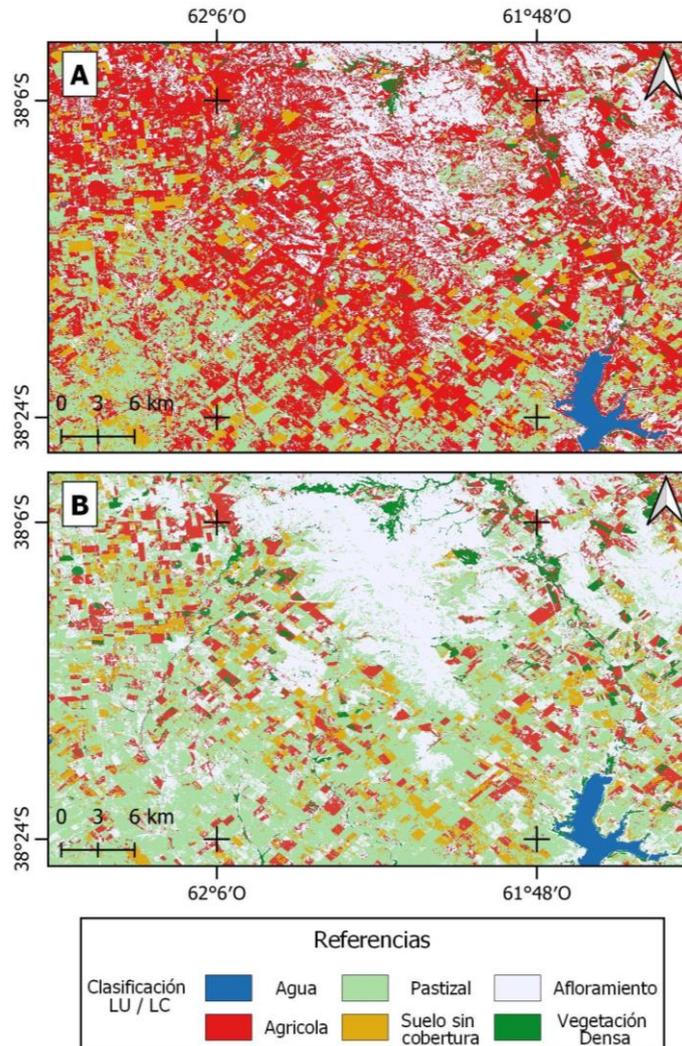


Figura 3. Mapas de LULC con seis categorías obtenidos con: A) SCP y B) GEE.

En la Tabla 5, se presentan los resultados de los estadísticos de calidad de la clasificación de seis categorías. Se destaca que la precisión y el índice kappa mejoraron en SCP y GEE al reducir la complejidad de la clasificación a través de la disminución del número de clases, especialmente en SCP, pasando de 77.6 % a 87.9%. La performance más baja en GEE fue para la clasificación de la categoría agrícola. En el caso de SCP, las mayores dificultades se observaron en la identificación del pastizal. SCP tuvo mejor desempeño que GEE para clasificar suelo sin cobertura y áreas agrícolas y fue igual en ambos casos para el agua. GEE fue mejor para clasificar vegetación densa, afloramiento y pastizal.

Tabla 5. Estadísticos de la clasificación de 6 categorías según GEE y SCP

Estadístico	Plataforma	Sc	A	P	Vd	Af	Ag
PA (%)	SCP	95.00	90.16	60.00	81.25	88.00	100
	GEE	88.23	85.71	87.50	100	96.96	100
UA (%)	SCP	90.48	87.30	60.00	92.86	89.80	100
	GEE	83.33	85.71	95.45	100	94.11	100
Precisión total (%)	SCP	87.88					
	GEE	97.83					
Kappa	SCP	0.84					
	GEE	0.95					

Es importante destacar que la clasificación se realizó por medio de RF, dado que es el más utilizado y con mejores resultados [35]. No obstante, [21] compararon los distintos algoritmos de clasificación disponibles en SCP y hallaron que, para su caso de estudio, el algoritmo de máxima verosimilitud tuvo la mejor performance. Estos autores no incluyeron en su análisis RF. Otro punto a considerar es que la precisión y el índice kappa mejoran al reducir la complejidad de la clasificación, dado que se unificaron las clases de cultivos que presentan gran similitud espectral. No obstante, si se comparan las superficies de cada una de las categorías, existen mayores similitudes entre SCP y GEE en la clasificación de donde se segregan los diferentes cultivos.

Por otra parte, si se comparan los resultados con los obtenidos por el INTA para la campaña 2022/2023 [41], el mapa arrojó una precisión total del 76% y un coeficiente Kappa de 0.63 para la zona XI (Sudoeste de Buenos Aires - Sur de La Pampa), que contiene al área de estudio. Si bien la leyenda empleada en este producto presenta diferencias con respecto a la utilizada en este trabajo, es posible realizar algunas comparaciones. En principio, en la clasificación del INTA, no identifica superficie ocupada por sorgo y aquellas clasificadas como cultivo de maíz, girasol y como suelo sin cobertura son inferiores a las detectadas por las clasificaciones realizadas en GEE y SCP, presentadas en este trabajo. De esta manera, los resultados obtenidos empleando estas dos herramientas poseen mayores similitudes entre sí, si comparamos con respecto al inventario nacional de cultivos que provee el INTA. Con respecto a la categoría de pastizal, no se realizan comparaciones debido a que en el mapa nacional de cultivos se encuentra incluida dentro de la clase “no agrícola”, que además incluye afloramiento y zonas urbanas, entre otras. Es así que se plantea que para la zona XI, específicamente para el centro sur del sistema de Ventania donde se localiza el área de estudio del presente trabajo, podría ser necesaria una subdivisión que permita mejorar la representación de sus características en futuros inventarios de cultivos.

En términos del uso y funcionalidades de las herramientas empleadas en el análisis presentado, se identificaron algunos puntos a tener en cuenta para la elección entre ellas. El SCP no requiere de conocimientos en programación y, siendo que se utiliza

dentro de QGIS, sólo demanda conocimientos en el manejo de SIG. En SCP, la totalidad del proceso de clasificación puede llevarse a cabo dentro de QGIS y posee una interfaz más amigable y con mayores funcionalidades que GEE para obtener productos finales, como cartografía temática. No obstante, en GEE la totalidad de la clasificación se realiza de forma automática. Esto, sumado al procesamiento en la nube, hace que se reduzcan los tiempos necesarios para obtener el producto final. Por este motivo, GEE favorece la realización de múltiples pruebas que permitan alcanzar los valores óptimos de las distintas variables involucradas en la clasificación. GEE permite mejorar las clasificaciones, por ejemplo, a través de la aleatorización de la selección de los subconjuntos de muestras para entrenamiento y validación, mientras que, en el SCP, si bien es posible seleccionar aleatoriamente las mismas, el proceso es estático. Asimismo, GEE permite realizar una colección de imágenes de un periodo dado para obtener los valores medios de la ROI y así, evitar que los resultados se vean afectados por valores atípicos, en cambio, SCP sólo permite realizar la clasificación con una única imagen. Finalmente, ambas plataformas son de acceso libre y poseen una gran comunidad de apoyo que facilita su uso y la solución de problemas que pudieran surgir en el proceso de clasificación.

4 Conclusiones

A partir del análisis realizado, se puede concluir que tanto GEE como SCP permiten el procesamiento de imágenes satelitales y la obtención de información geográfica de usos y coberturas del suelo con resultados aceptables en términos estadísticos. La precisión total de las clasificaciones varió entre 77.60 % y 87.88 % en SCP y entre 93.91% y 97.83% en GEE. En ambos casos, las estadísticas mejoran al reducir la complejidad de las clasificaciones, unificando las clases con grandes similitudes espectrales, lo que facilita su identificación.

La elección de GEE o del SCP como herramientas para la realización de clasificaciones de LULC dependerá principalmente del objetivo final y necesidades del trabajo, así como del usuario de la herramienta. En el caso de usuarios con conocimientos generales en SIG, que requieran ocasionalmente mapas de LULC para diversas aplicaciones, el SCP permite obtener resultados aceptables sin demandar tiempo de formación en herramientas específicas, como las necesarias para la utilización del GEE. No obstante, GEE permite la automatización del proceso y la reducción de los tiempos de procesamiento, por lo que puede ser más útil para aplicaciones de monitoreo de los usos y coberturas del suelo y sus cambios en el tiempo, tanto para el sector agrícola como para la gestión territorial.

Agradecimientos. El presente trabajo se realizó en el marco del proyecto “Geografía Física Aplicada al estudio de la interacción sociedad-naturaleza. Problemáticas ambientales a diferentes escalas témporo-espaciales”. Dirección: Dra. Verónica Gil. Código: 24/G092. Secretaría General de Ciencia y Tecnología, Universidad Nacional del Sur. Federico J. Berón de la Puente y Anabella Montico son estudiantes del Doctorado en Ciencias Aplicadas mención Ambiente y

Salud (DCAAS), Universidad Nacional del Centro de la provincia de Buenos Aires (UNCPBA), Argentina.

Referencias

1. Jobbágy, E. G. “Servicios hídricos de los ecosistemas y su relación con el uso de la tierra en la llanura chaco-pampeana”. En: Valoración de Servicios Ecosistémicos Conceptos, herramientas y aplicaciones para el ordenamiento territorial, editado por Pedro Laterra, Esteban G. Jobbágy y José M. Paruelo. Buenos Aires: Ediciones INTA. (2011).
2. López Laxague, J., García, P. E., Menéndez, Á. y Bert, F.: Influencia sobre el nivel freático en zonas de llanura debido al efecto del cambio en el uso del suelo y los condicionantes climáticos. En: 2do Encuentro de Investigadores en Formación en Recursos Hídricos IFRH, Ezeiza, Buenos Aires, Argentina. (2014).
3. Villamizar, S. R., Pineda, S. M., and Carrillo, G. A.: The effects of land use and climate change on the water yield of a watershed in Colombia. *Water*. 11(2), 285-304 (2019). <https://doi.org/10.3390/w11020285>
4. Sequeira, N. D., Vazquez, P. y Sacido, M.: Erosión hídrica y su relación con el avance de la agricultura en el sudeste bonaerense, Argentina. El caso del partido de Benito Juárez durante las campañas 1989/90, 2002/03 y 2014/15. *Papeles de Geografía*. (65), 106–120 (2019). <https://doi.org/10.6018/geografia.395691>
5. Villao-González, C. A. y Cabrera-Estupiñan, E.: Cuantificación de procesos erosivos en la Cuenca Portoviejo, propuesta para un modelo de gestión. *Dominio De Las Ciencias*. 7(5), 870–890 (2021). <https://doi.org/10.23857/dc.v7i5.2287>
6. Bonansea, M., Bazán, R., Germán, A., Ferral, A., Beltramone, G., Cossavella, A. and Pinotti, L.: Assessing land use and land cover change in Los Molinos reservoir watershed and the effect on the reservoir water quality. *Journal of South American Earth Sciences*. 108, 103243. (2021). <https://doi.org/10.1016/j.jsames.2021.103243>
7. Andrade, V. S., Gutierrez, M. F., Regaldo, L., Paira, A. R., Repetti, M. R., and Gagnetten, A. M.: Influence of rainfall and seasonal crop practices on nutrient and pesticide runoff from soybean dominated agricultural areas in Pampean streams, Argentina. *Science of the Total Environment*. 788, 147676 (2021). <https://doi.org/10.1016/j.scitotenv.2021.147676>
8. Paruelo, J., Alcaraz-Segura, D. y Volante, J. N. . El seguimiento del nivel de provisión de los servicios ecosistémicos. Valoración de Servicios Ecosistémicos. Conceptos, herramientas y aplicaciones para el ordenamiento territorial. Ediciones INTA, Buenos Aires, Argentina, 141-162. (2011).
9. Laterra, P., Barral, M.P., Carmona, A. y Nahuelhual, L.: ECOSER: protocolo colaborativo de evaluación y mapeo de servicios ecosistémicos y vulnerabilidad socio-ecológica para el ordenamiento territorial. Ediciones INTA, Buenos Aires, Argentina. (2015).
10. De Abelleyra, D., Veron, S., Bancharo, S., Mosciaro, M. J., Propato, T., Ferraina, A., Gómez Tafarel, M.C., Dacunto, L., Franzoni, A. and Volante, J.: First large extent and high resolution cropland and crop type map of Argentina. In: 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS) (pp. 392-396). (2020).
11. Binte Mostafiz, R., Noguchi, R. and Ahamed, T.: Agricultural Land Suitability Assessment Using Satellite Remote Sensing-Derived Soil-Vegetation Indices. *Land*. 10(2), 223-249 (2021). <http://dx.doi.org/10.3390/land10020223>
12. Bellón, B., Bégué, A., Seen, D.L., Almeida, C.A. and Simões, M.: A Remote Sensing Approach for Regional-Scale Mapping of Agricultural Land-Use Systems Based on NDVI Time Series. *Remote Sensing*. 9, 600-617 (2017). <https://doi.org/10.3390/rs9060600>

13. Thenkabail, P. S., Lyon, J. G., and Huete, A.: Advances in hyperspectral remote sensing of vegetation and agricultural crops. In *Fundamentals, Sensor Systems, Spectral Libraries, and Data Mining for Vegetation* (pp. 3-37). CRC press. (2018)
14. Dabija, A., Kluczek, M., Zagajewski, B., Raczko, E., Kycko, M., Al-Sulttani, A. H., Tardà A., Pineda, L., and Corbera, J.: Comparison of support vector machines and random forests for Corine Land Cover mapping. *Remote Sensing*. 13(4), 777-806 (2021). <https://doi.org/10.3390/rs13040777>
15. Abdi, A. M.: Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience & Remote Sensing*. 57(1), 1-20 (2020). <https://doi.org/10.1080/15481603.2019.1650447>
16. Khatami, R., Mountrakis, G., and Stehman, S. V.: A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote sensing of environment*. 177, 89-100 (2016). <http://dx.doi.org/10.1016/j.rse.2016.02.0280034-4257/>
17. Nery, T., Sadler, R., Solis-Aulestia, M., White, B., Polyakov, M., and Chalak, M.: Comparing supervised algorithms in Land Use and Land Cover classification of a Landsat time-series. In: *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* pp. 5165-5168. (2011)
18. Poursanidis, D., Chrysoulakis, N., and Mitrika, Z.: Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urban land cover mapping. *International Journal of Applied Earth Observation and Geoinformation*. 35, 259-269 (2015). <https://doi.org/10.1016/j.jag.2014.09.010>
19. Astola, H., Häme, T., Sirro, L., Molinier, M., and Kilpi, J.: Comparison of Sentinel-2 and Landsat 8 imagery for forest variable prediction in boreal region. *Remote Sensing of Environment*. 223, 257-273. (2019). <https://doi.org/10.1016/j.rse.2019.01.019>
20. Congedo, L.: Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*. 6(64), 3172. (2021). <https://doi.org/10.21105/joss.03172>
21. Pereira, L. F., and Guimarães, R. M. F.: Mapeamento multicategórico do uso/cobertura da terra em escalas detalhadas usando Semi-automatic Classification Plugin. *Journal of Environmental Analysis and Progress*. 379-385. (2018). <https://doi.org/10.24221/jeap.3.4.2018.2016.379-385>
22. Tempa, K., and Aryal, K. R.: Semi-automatic classification for rapid delineation of the geohazard-prone areas using Sentinel-2 satellite imagery. *SN Applied Sciences*. 4(5), 141. (2022). <https://doi.org/10.1007/s42452-022-05028-6>
23. Leroux, L., Congedo, L., Bellón, B., Gaetano, R., and Bégué, A.: Land cover mapping using Sentinel-2 images and the semi-automatic classification plugin: A Northern Burkina Faso case study. *QGIS and Applications in Agriculture and Forest*. 2, 119-151. (2018). <https://doi.org/10.1002/9781119457107.ch4>
24. Google (2022). Google Earth Engine. <https://earthengine.google.com/>, ultimo acceso 2023/5/8
25. Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q. and Brisco, B.: Google earth engine cloud computing platform for remote sensing big data applications: A comprehensive review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 13, 5326-5350 (2020). <https://doi.org/10.1109/JSTARS.2020.3021052>
26. Coca-Castro, A., M. A. Zaraza-Aguilera, Y. T. Benavides-Miranda, Y. M. Montilla-Montilla, H. B. Posada-Fandiño, A. L. Avendaño- Gómez, H. A. Hernández-Hamon, S. C.

- Garzón-Martínez, y C. A. Franco-Prieto.: Evaluación de algoritmos de clasificación en la plataforma Google Earth Engine para la identificación y detección de cambios de construcciones rurales y periurbanas a partir de imágenes de alta resolución. *Revista de Teledetección*. 58 (58): 71–88. (2021). <https://doi.org/10.4995/raet.2021.15026>
27. Kaur, H., Tyagi, S., Mehta, M. and Singh, D.: Time series (2001/2002–2021) analysis of Earth observation data using Google Earth Engine (GEE) for detecting changes in land use land cover (LULC) with specific reference to forest cover in East Godavari Region, Andhra Pradesh, India. *Journal of Earth System Science*. 132, 86. (2023). <https://doi.org/10.1007/s12040-023-02099-w>
 28. Gil, V. y Campo, A.: Cuenca del Arroyo del Oro: Características hidrográficas y los efectos sobre la población. En *Actas III Jornadas de Geografía Física, Universidad del Litoral*. pp 153-159 (2000).
 29. Beron de la Puente, F.; Gil, V. y Viale, M. Realzamiento orográfico de precipitaciones en las Sierras Australes bonaerenses. *Congremet XIV*, Buenos Aires. 2022. http://cenamet.org.ar/congremet/wp-content/uploads/2022/11/Programa_CONGREGMET_2022_20221109.pdf
 30. Scarpati, O. E. y Capriolo, A. D.: Sequías agrícolas: recurrencia, clasificación y distribución en la Región Pampeana argentina. *Cuadernos Geográficos*. 55(1), 6-32 (2016).
 31. Instituto Nacional de Tecnología Agropecuaria INTA.: Mapa de Suelos de la provincia de Buenos Aires. Escala 1:500000. Buenos Aires. 525 pp. (1989)
 32. Instituto Nacional de Estadísticas y Censos INDEC. Censo Nacional Agropecuario. (2018).
 33. Flood, N.: Seasonal composite Landsat TM/ETM+ images using the medoid (a multi-dimensional Median). *Remote Sensing*. 5(12), 6481-6500 (2013). <https://doi.org/10.3390/rs5126481>
 34. Congalton, R. G.: *Remote sensing: models and methods for image processing*. 2nd ed. Academic Press. (1999).
 35. Chen, W., Xie, X., Wang, J., Pradhan, B., Hong, H., Bui, D. T., Duan, Z. and Ma, J.: A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. *Catena*. 151, 147–160 (2017). <https://doi.org/10.1016/j.catena.2016.11.032>
 36. Nguyen, C.T.; Chidthaisong, A., Kieu Diem, P. and Huo, L. Z.: A modified bare soil index to identify bare land features during agricultural fallow-period in southeast Asia using Landsat 8. *Land*. 10(3), 231 (2021). <https://doi.org/10.3390/land10030231>
 37. Zha, Y., Gao, J. and Ni, S.: Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International journal of remote sensing*. 24(3), 583-594 (2003). <https://doi.org/10.1080/01431160304987>
 38. Metternicht, G.: Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*. 24(14), 2855-2877 (2003). <https://doi.org/10.1080/01431160210163074>
 39. Rouse, J.W., Haas, R.H., Schell, J.A. and Deering, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In *3rd ERTS Symposium, NASA SP-351 I*, 309-317. (1973).
 40. Gao, B. C.: NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*. 58(3), 257-266 (1996). [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
 41. Instituto Nacional de Tecnología Agropecuaria INTA.: Mapa nacional de cultivos. Campaña 2022/2023. (2023).