

## Clasificación Inteligente de Cultivos de Verano en la Plataforma Google Earth Engine

Beron de la Puente Federico Javier<sup>1,2</sup>[0000-0003-4228-4593], Revollo Natalia<sup>3,4</sup>[0000-0002-2591-9123] and Gil Verónica<sup>1,2</sup>[0000-0002-2824-204X]

<sup>1</sup> Departamento de Geografía y Turismo, Universidad Nacional del Sur, Argentina

<sup>2</sup> Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina

<sup>3</sup> Departamento de Ingeniería Eléctrica y de Computadoras, Universidad Nacional del Sur, Argentina.

<sup>4</sup> Instituto de Ciencias e Ingeniería de la Computación - ICIC (CONICET/UNS), Argentina  
fjberon@criba.edu.ar, nrevollo@criba.edu.ar, verogil@uns.edu.ar

**Resumen.** El monitoreo espacial de zonas agrícolas es de fundamental importancia para la toma de decisiones económicas, sociales y políticas. El objetivo de este trabajo es obtener un modelo de clasificación supervisada de cultivos de verano mediante técnicas de aprendizaje de máquina a partir del uso de imágenes multiespectrales. La región elegida es el centro-sur del sistema de Ventania, en el sudoeste de la provincia de Buenos Aires, Argentina. Para la implementación del modelo basado en Random Forest (RF) se utilizó información de bandas e índices espectrales obtenidos a partir de imágenes Sentinel 2 en la plataforma Google Earth Engine (GEE). En el modelo obtenido la precisión global supera el 94%, donde se pudo discernir con una gran fiabilidad los cultivos de maíz, sorgo, girasol y pastizales. Estos resultados iniciales demuestran ser una valiosa herramienta para la gestión agrícola y la implementación de GEE facilitó la automatización de todo el proceso, reduciendo los tiempos de trabajo.

**Keywords:** Sistemas de monitoreo, imágenes satelitales, Agricultura, aprendizaje de máquina.

### 1 Introducción

Argentina, se ha convertido en los últimos años en uno de los máximos exportadores de granos a nivel mundial [1]. La producción de granos está enfocada principalmente en cultivos de soja, maíz, trigo y cereales y hubo un incremento de 45 a 212 millones de toneladas entre 1990 y 2021 [2]. En el partido de Tornquist de la provincia de Buenos Aires los principales cultivos destinados para la siembra son el trigo, el maíz, la cebada y la avena. Estos representan el 40% de su superficie, aproximadamente unas 150.000 Ha [3]. Debido a la actividad agrícola en el país, es de fundamental importancia contar con características descriptivas e información espacial de la superficie sembrada. Esta información es aplicable para la estimación de rendimientos o estados fenológicos de

los cultivos que sirvan de apoyo a la toma de decisiones de actores económicos, sociales y políticos.

A nivel mundial se han realizado diversos esfuerzos para la gestión de información de cultivos en diversas escalas espacio-temporales. En 1992 el U.S. Geological Survey (USGS) realizó el territorio de los Estados Unidos el National Land Cover Database (NLCD) y desde el 2001 se actualiza cada 5 años. Para su creación dispone imágenes Landsat de 30m de resolución. El NLCD proporciona características de la superficie terrestre (zona urbana, agrícola, forestal), porcentaje de superficie impermeable y cubierta de la copa de los árboles [4]. En Canadá, el primer inventario por parte del Canada's Land Cover del Centre for Remote Sensing (CCRS) se llevó a cabo en el año 2000, con una actualización del catálogo cada 5 años y el último disponible es del año 2020. A diferencia del NLCD, ofrece una clasificación de 30 clases de uso y cobertura del suelo mediante el uso de imágenes satelitales Landsat con resolución de 30 m [5]. Por otra parte, el Corine Land Cover (CLC) por Copernicus Land Monitoring Service ha llevado a cabo inventarios suelos para Europa para diferentes instancias, y es en el año 2018 donde se utilizaron imágenes Sentinel-2 con una resolución de 10 m [6]. Esto ofreció una mejor resolución espacial y se elaboró un inventario de clasificación de más de 40 clases, siendo uno de los más detallados para su territorio. En los últimos años, Latinoamérica se ha sumado con proyectos de monitoreo satelital. En México, el Monitoring Activity Data donde desarrolla un inventario forestal y de suelos. En Colombia, el monitoreo de bosques y recursos forestales por medio del Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM). El Centro de Información de Recursos Naturales (CIREN) de Chile realiza monitoreo del uso actual del suelo y estudia la erosión. Brasil posee el proyecto de mapeo anual de uso y cobertura del suelo (Map Biomas), el cual produce mapas anuales de uso y cobertura del suelo [7]. En particular, en Argentina, el Instituto Nacional de Tecnología Agropecuaria (INTA) desarrolló mapas de cultivos para las principales áreas agropecuarias del país [8]. Los índices son derivados de imágenes satelitales Landsat de 30 m de resolución y las muestras de entrenamiento y validación fueron obtenidas a partir de relevamientos a campo e información complementaria. Se realizaron para campaña de invierno y de verano. Los mapas se actualizan cada año e incluyen las campañas 2018/2019, 2019/2020, 2020/2021 y 2021/2022.

Un aspecto común entre los programas llevados a cabo para generar inventario de suelos es el uso de la teledetección, donde mediante información provista de sensores remotos, se adquieren imágenes de alta resolución, son procesadas e interpretadas para extraer información de las diferentes coberturas presentes en el suelo [9]. Las misiones satelitales proporcionan imágenes ópticas multiespectrales de alta resolución donde registran la radiación reflejada por la superficie del planeta de manera periódica, sistemática y objetiva a lo largo de extensas superficies. Todas estas ventajas y facilidades a la hora de la adquisición de las imágenes, hace que el sensado remoto sea considerado como una alternativa cada vez más viable para la obtención de información precisa y actualizada para la caracterización de cubiertas vegetales [10, 11, 12, 13].

Sumado a esto, en los últimos años en el campo de la informática han surgido nuevas tecnologías, como la computación en la nube y en paralelo, aprendizaje de máquinas (machine learning), que han hecho que se disminuyan costos de infraestructura así

mismo tiempos de procesamiento y evaluación. Estas tecnologías permiten el acceso y procesamiento de grandes volúmenes de datos en diferentes escalas espacio-temporales. Google Earth Engine (GEE) es una plataforma de desarrollo para el análisis y procesamiento de datos geospaciales que cuenta con un catálogo de imágenes satelitales gratuitas de varios petabytes, el cual es posible usar gratuitamente [14]. Además, posee una plataforma que permite generar algoritmos para el procesamiento de la información satelital. GEE es utilizada ampliamente para diferentes áreas que van desde la agricultura, áreas forestales, monitoreo de superficie de humedales [15, 16, 17, 18, 19].

El objetivo de esta investigación es obtener un modelo de clasificación supervisada de cultivos de verano mediante técnicas de aprendizaje de máquina. A partir del uso de imágenes multiespectrales del satélite Sentinel 2. Para ello se tomará como procesamiento la plataforma Google Earth Engine para el sector centro sur del sistema de Ventania, en el sudoeste de la provincia de Buenos Aires, Argentina. De esta manera se mejorará la resolución espacio – temporal y se sumarán otras coberturas a las clasificadas por el INTA (suelos sin cobertura, zonas de afloramiento de roca y cuerpos de agua).

## **2 Materiales y Métodos**

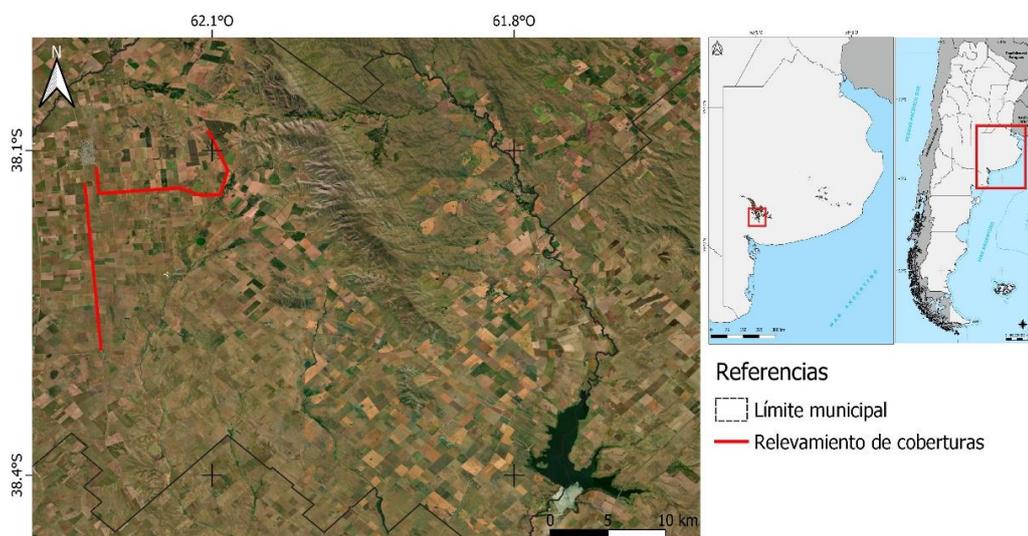
### **2.1 Área de estudio**

El área de estudio corresponde al sector centro sur del sistema de Ventania, ubicado entre los siguientes partidos, oeste de Tornquist, sur del partido de Coronel Suárez, este de Coronel Pringles y el norte de Bahía Blanca. Los mismos están ubicados en el suroeste de la provincia de Buenos Aires, Argentina (Fig. 1). Aquí se superponen dos unidades geomorfológicas que le dan características singulares a esta región sur de la gran llanura chaco-pampeana argentina: la llanura caracterizada por la ausencia de fuertes contrastes en su topografía y desarrollo de suelos apto para el cultivo y el Sistema de Ventania caracterizado por afloramientos rocosos cuyas alturas no superan los 1250 m s.n.m.

Es una zona climática templada seca - subhúmeda que está caracterizada por una sucesión de ciclos húmedos y secos que se manifiesta en variaciones temporales, estacionales e interanuales de los montos de precipitación [20]. Este ámbito serrano también posee una condición de variabilidad de las lluvias que se acentúa por la altura y la orientación de las laderas [21]. 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 [22].

Los suelos característicos de la cuenca están formados por sedimentos loésicos, estos son aptos para actividades productivas y por ello, en mayor medida el área de estudio está vinculada con la agricultura. En cuanto a las actividades económicas que caracterizan al área, el desarrollo de agricultura (principalmente cultivo de cereales) y ganadería (cría de bovinos). Esto define el perfil productivo de la región. Para el caso en particular del partido de Tornquist, unidad territorial donde se localiza el área central del estudio, predominan las actividades de agricultura por sobre las de ganadería. La

actividad que se desarrolla en la estancia, donde se realizan las mediciones pluviométricas, es representativa de los suelos y del funcionamiento productivo del área.



**Fig. 1.** Área de Estudio: Centro Sur del Sistema de Ventania en la Provincia de Buenos, Argentina. En rojo se muestran las transectas de las coberturas del terreno obtenidas mediante el relevamiento in situ.

## 2.2 Modelo de clasificación

Frente a la disponibilidad de imágenes multiespectrales, en este trabajo se utilizaron las imágenes Sentinel-2 distribuidas por la Agencia Espacial Europea (ESA). En el caso del área de estudio, este programa ofrece una mayor disponibilidad de imágenes espacio-temporales. Ya que el período de revisita es de 10 días entre los satélites 2A y 2B. Sumado a esto, el sensor Multi-Spectral Instrument (MSI), está diseñado para posibilitar la detección de vegetación con una resolución espacial de 10 o 20 m. La metodología de trabajo siguió mediante 3 etapas, que se describen a continuación:

### Etapa 1:

Para el procesamiento de las imágenes satelitales se utilizaron los servicios de cloud computing provistos por la plataforma de GEE. Lo que permitió acceder a los datos satelitales de 13 bandas espectrales que incluyen bandas en el rango del visible, infrarrojo cercano y medio. El dataset empleado es la colección “COPERNICUS/S2\_SR” que recoge las imágenes Sentinel 2 con nivel 2A de pre-procesado. Dónde están corregidas atmosféricamente y con valores de reflectancia en la parte inferior de la atmósfera (Bottom Of Atmosphere, BOA). Esta colección fue acotada según el porcentaje de nubosidad a partir de un recorte del área de estudio, para este caso corresponde al 5% y el intervalo de tiempo se acotó para el mes de marzo 2023 donde se realizó la campaña de relevamiento de cultivos.

En esta etapa, se obtuvo una imagen de la zona de estudio representada por un mosaico de imágenes medianas. Los valores de reflectancia en las imágenes medianas no son afectados por valores atípicos [23, 24]. A partir de esta imagen, se priorizan algunas bandas e índices espectrales que se consideran importantes en la obtención de coberturas de suelo [25, 26, 27].

**Tabla 1.** Bandas e índices espectrales obtenidos para la clasificación

Nombre	Significado	Fórmula	Fuente
B5	Band Roja (Red)	-	-
B8	Banda Infrarrojo cercano (NIR)	-	-
BSI	Índice de Suelo Desnudo	$((Red+SWIR) - (NIR+Blue)) / ((Red+SWIR) + (NIR+Blue)) (1)$	[28]
NDBI	Índice de áreas construidas de diferencia normalizada	$(SWIR - NIR) / (SWIR + NIR) (2)$	[29]
PVR	Relación de vigor fotosintético	$(Green - Red) / (Green + Red) (3)$	[30]
NDVI	Índice de vegetación de diferencia normalizada	$(NIR - Red) / (NIR + Red) (4)$	[31]
NDWI	Índice de diferencia Normalizada agua	$(Green - NIR) / (Green + NIR) (5)$	[32]

#### Etapa 2:

Al plantear una clasificación de coberturas es necesario disponer de una base de datos in situ que sirva tanto para el entrenamiento como para la validación del modelo clasificador. En este caso se tomaron una serie de parcelas cuya clase de cobertura fue identificada en campañas que se llevaron a cabo en el terreno mediante un grupo de expertos. Para la obtención de la información, el recorrido comprende de 2 transectas de 20 km cada una (Fig. 1). Por medio de instrumental GPS se identificaron y relevaron las parcelas con las clases de suelo sin cobertura (Sc), pastizal (P), maíz (M), sorgo (S), girasol (G). Por otro lado, se creó un mosaico RGB de una imagen Sentinel 2 obtenida para el mes de marzo. Mediante fotointerpretación se identificaron cuerpos de agua (Ag), afloramiento rocoso (Af) y vegetación del tipo arbustiva, arbórea como vegetación densa (Vd). Para ambos casos se trazaron los diferentes polígonos a partir del relevamiento de las 9 clases. El entrenamiento y validación del modelo fue a partir de una imagen stack creada con las bandas e índices espectrales definidos en la etapa 1.

La muestra se dividió en dos conjuntos de datos: uno correspondiente al de entrenamiento y el otro al de validación. Para la selección del conjunto de datos de validación en donde el 20% del total de la muestra corresponde a la información de validación y el 80% se utilizó para entrenamiento quedando 402 y 1502 respectivamente. Además, los datos para entrenar y validar el modelo fueron seleccionados de forma aleatoria.

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 es Random Forest (RF) (ee.Classifier.smile-RandomForest), pues según la revisión literaria realizada es el más usado y con mejores resultados, obteniendo la mejor exactitud temática para la adquisición de información

agropecuaria [33, 34, 35, 36]. Los parámetros utilizados en el algoritmo RF son 600 árboles debido a que presentaron el mejor rendimiento de la clasificación y el número de ramificaciones fue establecido de acuerdo a la recomendación teórica la raíz cuadrada del número de clases objetivo dando un valor de 3 [37].

Una vez obtenida la imagen clasificada, se obtuvieron los indicadores de la calidad temática, esta evaluación de fiabilidad permite evaluar el procedimiento realizado y su calidad en el resultado final. Se utilizaron las métricas más representativas a la hora de clasificar una cobertura del suelo, corresponden a porcentaje de clasificación del mapa general, calidad del productor, calidad del usuario y el índice kappa (k), este último debido a que no posee sesgo derivado de los errores de omisión y comisión. Los anteriores indicadores son derivados de la matriz de confusión generada a partir de la comparación del resultado de la clasificación y la muestra definida para la validación. La clasificación final se selecciona a partir de la revisión de los indicadores de exactitud temática junto a una validación visual aleatoria de las coberturas clasificadas.

Etapas 3:

La imagen final clasificada se exporta a Google drive para que se aplique un post-procesado por medio del software ArcMap 10.3.1 eliminando píxeles aislados o el ruido de la salida de la imagen clasificada por medio del proceso Majority Filter.

### 3 Resultados

En los recorridos a campo, se identificaron un total de 10 lotes girasol, 10 lotes de maíz, 18 lotes de pastizal, 15 lotes de sorgo, 12 lotes de suelo sin cobertura. A partir de este relevamiento inicial se trazaron polígonos para cada clase. Donde 30 polígonos se digitalizaron para cada una de las coberturas girasol, maíz, suelo desnudo. Mientras que, para pastizales, cultivos de sorgo se digitalizaron 50 polígonos. Para la vegetación densa se crearon 30 polígonos y para los cuerpos de agua y afloramiento rocosos de las sierras se utilizaron una capa de puntos, donde los sets de muestras se conforman con 40 y 180 puntos cada uno. La disparidad en la cantidad de muestras de puntos para la clase afloramiento, se debe a que era necesario una mayor cantidad de puntos para que el modelo pueda tener una mejor precisión para poder clasificar estas últimas clases.

En la tabla 1 podemos observar el resultado de la matriz de confusión que se obtuvo mediante los datos de validación y, por otro lado, el desempeño del modelo. Es posible notar que, en la validación del modelo, la precisión general entregó un valor de 0.94 y el coeficiente k 0.90. Este último valor indica que hay una alta proporción de coincidencias para el modelo, dado que el valor supera a 0.80. En general, los valores de exactitud del productor y consumidor son superiores a 0.68, asegurando una alta probabilidad de aciertos. En la figura 2 se muestra el resultado final de la clasificación para el área de estudio.

Para la identificación individual de los cultivos de maíz, sorgo y girasol se eligió entre las fechas de floración de los distintos cultivos y momentos antes a la cosecha, ya que es el momento donde más fácilmente se puede identificar cada cultivo para poder obtener el mejor resultado posible del clasificador. Aun así, debido a la geografía del

lugar, el contexto climático de sequía, los resultados tienden a confundir la clase afloramiento con suelos desnudos y se omitió generar una clase de zona urbana. Esto es debido a las características particulares de las sierras y su respuesta espectral generaba confusión entre estas 3 clases, ya que dentro de la zona hay 3 pequeñas localidades con una baja densidad de construcción. Por otro lado, la clase vegetación densa que engloba a la vegetación arbustiva que se encuentra en los márgenes de los diferentes arroyos y zona de árboles generó cierta confusión con campos en los cuales se encontraba bajo riego por pivó o tenían una alta densidad de cultivos.

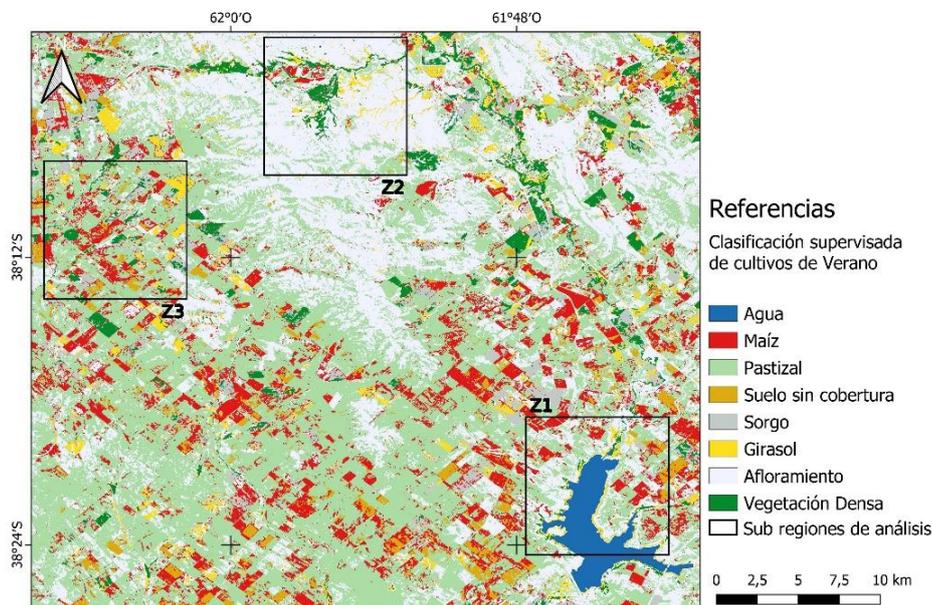
En cuanto a los diferentes cultivos, se pudieron obtener los siguientes resultados: la mayor superficie ocupada fue maíz con 274 km<sup>2</sup>, seguido del sorgo con 120 km<sup>2</sup> y girasol con 75 km<sup>2</sup>. Mientras que el suelo sin cobertura ocupa una superficie de 90 km<sup>2</sup> y la clase agua la cual representa en su totalidad la superficie del dique Paso de las Piedras (DPP) obtuvo una superficie de 28 km<sup>2</sup>.

**Tabla 2.** Matriz de confusión resultante del modelo RF a partir de los datos de validación

	Ag	M	P	Sc	S	G	Af	Vg	Exactitud del Usuario
Agua (Ag)	10	0	0	0	0	0	0	0	1.00
Maíz (M)	0	26	1	0	2	0	0	0	0.86
Pastizal (P)	0	1	20	0	0	0	1	0	0.68
Suelo sin cobertura (Sc)	0	2	3	16	0	0	2	0	0.94
Sorgo (S)	0	0	2	0	16	0	1	1	0.88
Girasol (G)	0	0	0	1	0	4	0	0	1.00
Afloramiento rocoso (Af)	0	1	3	0	0	0	34	1	0.89
Vegetación densa (Vg)	0	0	0	0	0	0	0	254	0.99
Exactitud del productor	1.00	0.89	0.91	0.70	0.80	0.80	0.87	1.00	

Precisión general: 0.945

Índice Kappa ( $k$ ): 0.905



**Fig. 2.** Resultado de la clasificación supervisada

A continuación, en la figura 3 se resaltan 3 regiones con diferentes características de cobertura y uso del suelo. En la primera (Z1) se puede observar la desembocadura del río Sauce Grande en el DPP donde sus márgenes fueron correctamente clasificados, pero según el modelo, en los bordes que siguen al mismo, se encuentran cultivos de girasol (amarillo), lo cual está incorrectamente clasificado. Esto se puede deber a que, en los recorridos que se realizó se encontraron pocos lotes de este cultivo. También en Z1 hay sectores donde la clase suelo desnudo se confunde con la clase afloramiento.

Por otra parte, Z2 muestra la localidad de Villa Ventana. Esta zona tiene la característica de una muy baja densidad de construcción y una alta cantidad de vegetación en forma de cubierta de árboles. Como resultado, la imagen queda clasificada como vegetación densa. La zona de las sierras está correctamente identificada (blanco) y hay una clara diferenciación del pastizal (verde claro). Donde el modelo tuvo confusión fue con la cobertura girasol (amarillo) el cual aparece de forma incorrecta entre lo que sería en realidad parte de la red de drenaje temporaria del arroyo del Oro (afluente del río Sauce Grande).

Finalmente, en Z3 se focaliza la zona de cultivos. En la imagen RGB se puede observar el arroyo Napostá Grande y el arroyo del Águila, están caracterizados por ser intermitentes cubiertos de vegetación riparia. Esta vegetación posee una copa que se puede extender a ambos márgenes llegando al centro del cauce, sumado a que ambos arroyos en ciertos sectores su ancho no supera los 10 metros. Por este motivo, en esas zonas, el modelo clasificó como vegetación densa (verde oscuro). Además, esta zona se eligió debido a que hay cultivos bajo riego por pivote y este sistema su característica

identificatoria es su forma, ya que la siembra es de manera circular. Este tipo de sistemas de riegos por su gran densidad de vegetación y respuesta espectral está bajo la misma categoría que los márgenes de los arroyos (vegetación densa). La región Z3 destaca que los campos de cultivos (maíz, girasol, sorgo) se encuentran mapeados correctamente.

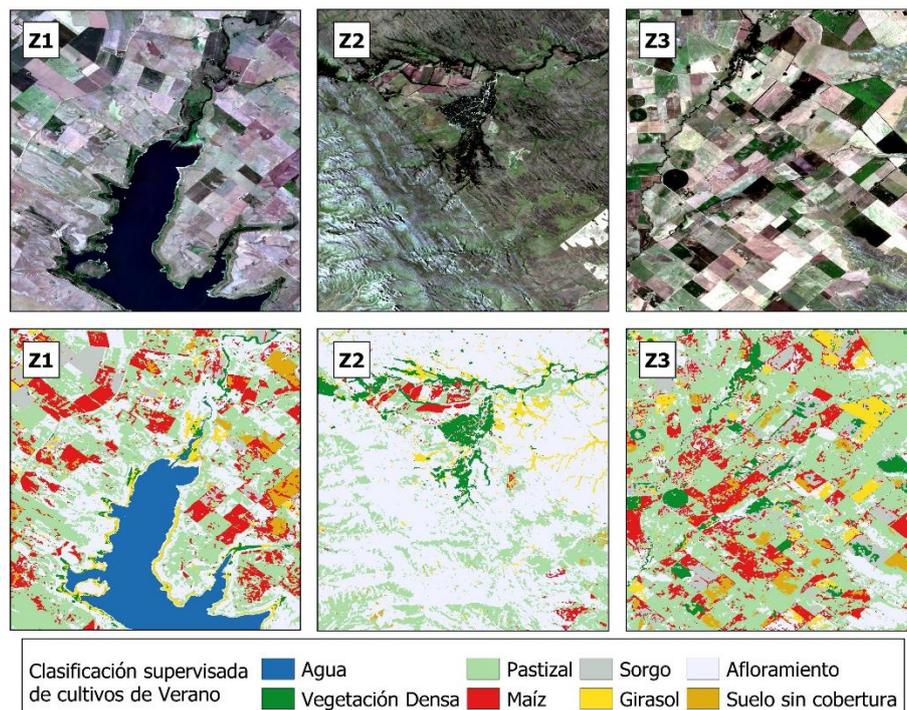


Fig. 3. Resultados del modelo observando 3 regiones diferentes de la zona de estudio

#### 4 Conclusiones

En el presente trabajo se ha obtenido un mapa de usos del suelo representando los cultivos de verano del año 2023 para la zona donde su principal actividad es la agrícola. Se pudo observar que las imágenes Sentinel 2 permitió en gran medida poder discernir los diferentes usos del suelo con gran exactitud mediante aplicar el modelo RF, el cual dio una precisión global del 94.5%. El modelo utilizado se diferencia del trabajo realizado por el INTA en que se adicionaron coberturas del ambiente serrano (afloramientos rocosos), cuerpos de agua, suelos sin cobertura y cultivo de sorgo. Estos resultados iniciales demuestran ser una valiosa herramienta para la gestión agrícola ya que es un paso para estimar en una gran superficie de forma automática la superficie cosechada. Un desafío a futuro es poder mejorar el modelo para que la clasificación separe correctamente los cultivos que utilizan sistemas de riego por pivote de la vegetación densa.

Por otro lado, la utilización de la plataforma Google Engine, ayudó a la reducción de tiempo en la adquisición de imágenes satelitales y el procedimiento de ejecución del modelo. Lo cual facilitó la automatización de todo el proceso, reduciendo los tiempos de trabajo y a futuro permitiría una mejora, si así se desea en futuros estudios de monitoreo de posibles cambios de cobertura del suelo o seguimiento de la fenología de ciertos cultivos claves para la actividad de la zona. Además, este tipo de clasificación, es un insumo importante para futuros trabajos relacionados con procesos de erosión hídrica que se dan en la zona del piedemonte serrano.

## Referencias

1. Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). 2022.
2. Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2022). FAOSTAT: base de datos de la Organización de las Naciones Unidas para la Alimentación y la Agricultura. <https://www.fao.org/faostat/es/#data>, último acceso 2023/5/8
3. Instituto Nacional de Estadística y Censos. (2018). Censo Nacional Agropecuario 2018: Resultados Definitivos. Buenos Aires, Argentina. Recuperado de [https://www.indec.gov.ar/ftp/cuadros/economia/cna2018\\_resultados\\_definitivos.pdf](https://www.indec.gov.ar/ftp/cuadros/economia/cna2018_resultados_definitivos.pdf)
4. Homer, C., Dewitz, J., Jin, S., Xian, G., Costello, C., Danielson, P., ... and Riitters, K. Conterminous United States land cover change patterns 2001–2016 from the 2016 national land cover database. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 184-199. (2020).
5. Pouliot, D., Latifovic, R., Zabic, N., Guindon, L. and Olthof, I. Development and assessment of a 250 m spatial resolution MODIS annual land cover time series (2000–2011) for the forest region of Canada derived from change-based updating. *Remote Sensing of Environment*, 140, 731-743. (2014).
6. Aune-Lundberg, L. and Strand, G. H. The content and accuracy of the CORINE Land Cover dataset for Norway. *International Journal of Applied Earth Observation and Geoinformation*, 96, 102266. (2021)
7. Santos, C. O. D., Mesquita, V. V., Parente, L. L., Pinto, A. D. S. and Ferreira Jr, L. G. Assessing the wall-to-wall spatial and qualitative dynamics of the Brazilian pasturelands 2010–2018, based on the analysis of the Landsat data archive. *Remote Sensing*, 14(4), 1024. (2022).
8. Ferreyra, A., Portillo, J. E., Bustos, D., and Lopresti, M. F. Mapa de cultivos de los partidos del Norte de la Provincia de Buenos Aires: trabajo conjunto entre INTA Pergamino y sus Agencias de Extensión Rural en el territorio agrícola, campaña 2020/2021. EEA Pergamino, INTA. (2021).
9. Chuvieco, E.: Teledetección ambiental. Barcelona. Ariel, S.A (2008).
10. Binte Mostafiz, R., Noguchi, R. and Ahamed, T. Agricultural Land Suitability Assessment Using Satellite Remote Sensing-Derived Soil-Vegetation Indices. *Land*. MDPI AG 10(2), 223. (2021), <http://dx.doi.org/10.3390/land10020223>
11. 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. Sens* 9, 600. (2017).
12. Thenkabail, P.S., Lyon, J.G. and Huete, A. Advances in hyperspectral remote sensing of vegetation and agricultural croplands. *Remote Sensing*, 3(11), 2447-2476. (2011). <https://pubs.er.usgs.gov/publication/70098951>

13. Jensen, J. R. and Jensen, R. R. Remote sensing of the environment: An earth resource perspective. 2nd edn. Pearson. (2007).
14. Google (2022). Google Earth Engine. <https://earthengine.google.com/>, ultimo acceso 2023/5/8
15. Shangguan, Y., Li, X., Lin, Y., Deng, J. and Yu, L. Mapping spatial-temporal nationwide soybean planting area in Argentina using Google Earth Engine. *International Journal of Remote Sensing*, 43, 1724 - 1748. (2022).
16. Smichowski, H., Contreras, F.I. and Giese, A.C. Seguimiento de la extensión areal de los humedales subtropicales del noreste de Argentina mediante la aplicación de Google Earth Engine. *Investigaciones Geográficas*, (78), 131–152. (2022), <https://doi.org/10.14198/INGEO.21343>
17. Fonnegra Mora, D.C., Walker, E. and Venturini, V. (2021). Flood monitoring in Santa Fe using the Google Earth Engine platform. 2021 XIX Workshop on Information Processing and Control (RPIC), 1-6. (2021).
18. Junior, C.A., Leonel-Junior, A.H., Rossi, F.S., Filho, W.L., Santiago, D.D., Oliveira-Júnior, J.F., Teodoro, P.E., Lima, M. and Capristo-Silva, G.F. Mapping soybean planting area in midwest Brazil with remotely sensed images and phenology-based algorithm using the Google Earth Engine platform. *Comput. Electron Agric.*, (169), 105194. (2020).
19. Kumar, L. and Mutanga, O. Google Earth Engine Applications Since Inception: Usage, Trends, and Potential. *Remote Sensing* 10 (10), 1509. (2018). <https://doi.org/10.3390/rs10101509>
20. 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. 153-159 (2000).
21. 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](http://cenamet.org.ar/congremet/wp-content/uploads/2022/11/Programa_CONGREGMET_2022_20221109.pdf)
22. Scarpati, O. E. y Capriolo, A. D. Sequías agrícolas: recurrencia, clasificación y distribución en la Región Pampeana argentina. *Cuadernos Geográficos*, v. 55, n. 1 (2016).
23. 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>
24. Congalton, R. G. Remote sensing: models and methods for image processing. 2nd edn. Academic Press. (1999).
25. Trujillo-Jiménez, M. A., Liberoff, A. L., Pessacq, N., Pacheco, C. and Flaherty, S. Metodología de clasificación automática de uso y cobertura de suelo. In *XIII Congreso de AgroInformática (CAI 2021)-JAIIO 50* (2021).
26. Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V.R., Murayama, Y. and Ranagalage, M. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote. Sens.*, 12, 2291 (2020).
27. Revollo Sarmiento, N., Pazos, P., Salomon, N. y Delrieux, C. Clasificación de cereales de invierno utilizando imágenes satelitales y técnicas de aprendizaje de máquina. XVIII Reunión de Trabajo en Procesamiento de la Información y Control - RPIC 2019, Bahía Blanca, Buenos Aires, Argentina. 2019.
28. 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>

29. 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>
30. 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>
31. 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).
32. 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)
33. Belgiu, M. and Csillik, O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment* 204(2018), 509–523. (2017), <https://doi.org/10.1016/j.rse.2017.10.005>
34. 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* vol 151, pp. 147–160. (2017), <https://doi.org/10.1016/j.catena.2016.11.032>
35. Dash, J. P., Pearse, G. D. and Watt, M. S. UAV multispectral imagery can complement satellite data for monitoring forest health. *Remote Sensing*, 10(8), 1–22. (2018). <https://doi.org/10.3390/rs10081216>
36. Zhao, L., Shi, Y., Liu, B., Hovis, C., Duan, Y. and Shi, Z. Finer Classification of Crops by Fusing UAV Images and Sentinel-2A Data. (2019).
37. Belgiu, M., & Drăgu, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. (2016), <https://doi.org/10.1016/j.isprsjprs.2016.01.011>