

Alciaturi, G., Umpiérrez, R., Agudelo, F., Panzl, R. Fernández, V. (2025). Cartografía del uso/cobertura del suelo a través del Geo Big Data: un enfoque para el año agrícola 2021-2022, Uruguay. *GeoFocus, Revista Internacional de Ciencia y Tecnología de la Información Geográfica* (Artículos), 35, 67-89. <https://dx.doi.org/10.21138/GF.844>

CARTOGRAFÍA DEL USO/COBERTURA DEL SUELO A TRAVÉS DEL *GEO BIG DATA*: UN ENFOQUE PARA EL AÑO AGRÍCOLA 2021-2022, URUGUAY

^{1,2a}Giancarlo Alciaturi , ^{2b}Rodrigo Umpiérrez, ^{2c}Fabiana Agudelo, ^{2d}Rebeca Panzl,
^{2e}Virginia Fernández

¹Facultad de Geografía e Historia, Universidad Complutense de Madrid, 28040 Madrid, España.

²División de Información Ambiental, Dirección Nacional de Calidad y Evaluación Ambiental,
Ministerio de Ambiente - Uruguay, 11100 Montevideo, Uruguay.

^agalciaatu@ucm.es, ^brodrigo.umpierrez@ambiente.gub.uy, ^cfabiana.agudelo@ambiente.gub.uy,
^drebeca.panzl@ambiente.gub.uy, ^evirginia.fernandez@ambiente.gub.uy

RESUMEN

La cartografía de uso y cobertura del suelo es una herramienta para comprender cómo la configuración del territorio influye sobre los componentes bióticos, abióticos y antrópicos. Las tecnologías de *Geo Big Data* permiten generar productos cartográficos de manera ágil y precisa. Esta investigación propone dos soluciones para mapear el uso y cobertura del suelo del Uruguay para el año agrícola 2021–2022. Los materiales comprendan las imágenes Sentinel 1 y Sentinel 2, Google Earth Engine, GEEMAP, Scikit-learn y los algoritmos *Random Forest* y *Support Vector Machines*. En cuanto a los métodos, sobresale la creación de un conjunto de datos multitemporal, el ajuste de los hiperparámetros y la clasificación supervisada a partir de los citados algoritmos. Se generaron dos mapas: S1S2RF_uy y S1S2SVM_uy. Ambos productos presentaron óptimos niveles de precisión, aunque S1S2RF_uy alcanzó un desempeño ligeramente superior, con una exactitud global del 83 % y un índice kappa de 0.81, frente al 81 % y 0.78 de S1S2SVM_uy. A nivel de clases, *Random Forest* mostró mayor capacidad para clasificar clases agrícolas, mientras que *Support Vector Machines* fue más eficaz en la identificación de coberturas artificiales como el tejido urbano. Se comprueba que el ajuste de los hiperparámetros es necesario para el óptimo aprovechamiento de los clasificadores. Con base en las estadísticas de fiabilidad, se evidencia que los recursos *Geo Big Data* son idóneos para una ágil creación de cartografía que representa todo el país bajo una resolución espacial media – alta. Futuras líneas deben considerar enfoques regionales y temporales distintos al año agrícola.

Palabras clave: *Geo Big Data*; Uso y Cobertura del suelo; Uruguay.

GEO-BIG DATA APPROACHES FOR LAND USE AND LAND COVER MAPPING: INSIGHTS FROM THE 2021–2022 AGRICULTURAL YEAR IN URUGUAY

ABSTRACT

Land use and land cover mapping is a key tool for understanding how territorial configuration influences biotic, abiotic, and anthropic components. In this regard, Geo Big Data technologies enable the agile and accurate generation of cartographic products. This study proposes two solutions for mapping land use and land cover in Uruguay for the 2021–2022 agricultural year. The inputs include Sentinel-1 and Sentinel-2 imagery, Google Earth Engine, GEEMAP, Scikit-learn, and the Random Forest and Support Vector Machines algorithms. The methodology highlights the creation of a multitemporal dataset, hyperparameters tuning, and supervised classification. As a result, two maps were generated: S1S2RF_uy and S1S2SVM_uy. Both products exhibited elevated levels of accuracy, although S1S2RF_uy performed slightly better, with an overall accuracy of 83 % and a kappa coefficient of 0.81, compared to 81 % and 0.78 for S1S2SVM_uy. At the class level, Random Forest showed a greater ability to classify agricultural covers, while Support Vector Machines were more effective in identifying artificial surfaces such as urban fabric. The findings confirm that hyperparameter tuning is essential for optimal classifier performance. Based on the reported accuracy statistics, it is also demonstrated that freely accessible Geo Big Data resources are well-suited for the efficient production of national-scale cartography at medium-to-high spatial resolution. Future research should prioritise regional focus and extend timeframes beyond the traditional agricultural year.

Keywords: Geo Big Data; Land Use / Land Cover; Uruguay.

1. Introduction

El uso y cobertura del suelo (UCS) es un efecto ejercido desde la gestión del territorio sobre la configuración del espacio geográfico. Particularmente, el enfoque “uso del suelo”, alude al papel que desempeña la dimensión humana en la utilización efectiva y funcional de un espacio sujeto a determinados condicionantes biofísicos. En contraste, la “cobertura del suelo”, es un enfoque centrado en el análisis de las características de los sustratos, ya sean naturales o artificiales, como han señalado diversos estudios (Lambin *et al.* 2001, Verburg *et al.* 2011, Sun y Schulz 2015, Wulder *et al.* 2018). Así, a través del UCS, se procura analizar la distribución espacial de clases asociadas a contextos geográficos cuyas dinámicas requieren de un análisis sustentado en la visión integrada de ambos enfoques. La configuración del UCS impacta en los componentes biótico, abiótico y antrópico del medioambiente. Por tanto, la cartografía de UCS es un instrumento para respaldar el análisis de fenómenos como el calentamiento global, la pérdida de hábitats, las migraciones masivas o las afectaciones en la calidad del agua (Meyer y Turner 1992, Darem *et al.* 2023). Esta cartografía, también se concibe como un instrumento para la comprensión de intervenciones vinculadas a escenarios de manejo de recursos naturales, la conservación de la biodiversidad, la planificación urbana e inclusive, la salud humana. El contexto geográfico del Uruguay es idóneo para analizarse bajo la perspectiva de UCS, ya que la existencia de los sustratos característicos de la región Pampeana y la ejecución de políticas de Estado, configuran un territorio con dinámicas donde se procura la preservación del medio ambiente junto al desarrollo de trascendentales actividades agrícolas y forestales.

Para cartografiar el UCS alusivo a superficies relativamente extensas (como las de dicho país) a partir de imágenes de resolución espacial media o alta, el uso de tecnologías informáticas convencionales puede requerir una inversión significativa de tiempo, lo que podría ralentizar la obtención ágil de resultados. No obstante, el auge del *Geo Big Data* (GeoBD), y en particular la rama centrada en la observación terrestre, también conocida como Big Earth Data, ayuda a superar estas limitaciones debido a su capacidad para realizar búsquedas y procesamientos de datos de manera eficiente, resultando en productos con niveles óptimos de precisión (Costa *et al.* 2022, Dahhani *et al.* 2022, Nasiri *et al.* 2022). En el ámbito de la Teledetección, la práctica del GeoBD se sustenta fundamentalmente en recursos como la Computación de Alto Rendimiento (HPC, por sus siglas en

inglés), los avances en Inteligencia Artificial (IA), los Datos Listos para el Análisis (ARD, por sus siglas en inglés) y las plataformas web libres para acceder y procesar los ARD.

La HPC, con su capacidad para superar las limitaciones intrínsecas de procesos reducidos y tiempos de cálculo extensos, se basa en el uso simultáneo de múltiples unidades centrales de procesamiento, agrupadas en nodos de cálculo y respaldadas por un bloque de memoria (IBM 2022). La HPC se destaca por su aplicación en la resolución de diversos desafíos científicos, empresariales y gubernamentales (United States Geological Survey 2022).

Previo al auge del GeoBD, fuentes como Lillesand *et al.* (2003) y Chuvieco (2008) subrayaron el potencial de los clasificadores como *Maximum Likelihood* (Máxima Verosimilitud), *Minimum Distance-to-Means* (Mínima Distancia a las Medias), *Mahalanobis Distance* (Distancia de Mahalanobis), *Parallelepiped* (Paralelepípedos) y *k-Nearest Neighbours* (k vecinos más próximos). Como fruto de los avances en la IA y debido a su capacidad para operar con GeoBD, la atención reciente se centra en alternativas como *Random Forest* (RF, Bosques Aleatorios), *Support Vector Machines* (SVM, Máquinas de Vectores de Soporte), CART y *Naïve Bayes* (Clasificador Bayes Ingenuo).

Los ARD son datos procesados bajo estándares científicos. Poseen consistencias geométricas y radiométricas que posibilitan el tratamiento directo para tareas de clasificación supervisada y no supervisada (Dwyer *et al.* 2018).

Para impulsar los estudios basados en estas tecnologías, son valiosas las plataformas web de acceso libre (Gomes *et al.* 2020, Wagemann *et al.* 2021), que permiten el almacenamiento y procesamiento de datos en la nube. Google Earth Engine (GEE) y Microsoft Planetary Computer son ejemplos destacados de estas herramientas. Tales recursos son adecuados para la búsqueda y el procesamiento eficiente de datos, como los adquiridos por las misiones Sentinel-1 (S1) y Sentinel-2 (S2). Estas sobresalen por brindar las más altas prestaciones en términos de resolución espacial, según sus respectivos objetivos de adquisición de datos mediante radar de apertura sintética (SAR) y sensores ópticos en acceso libre.

Dado el contexto, esta investigación tiene como objetivo, desarrollar y comparar dos soluciones para la cartografía del UCS correspondiente al año agrícola (AAG) 2021–2022 del territorio continental del Uruguay. Ambas alternativas se fundamentan en un conjunto de datos común, conformado por series temporales de S1 y S2. La diferencia entre las soluciones radica en el clasificador: una se apoya en RF y la otra en SVM. Se escoge el AAG porque ha sido un enfoque que predominantemente ha orientado el desarrollo de esfuerzos locales para gestar esta cartografía. Durante el período ocurren dinámicas biofísicas que condicionan el desarrollo de la agricultura, la cual, es de las intervenciones antrópicas que más contribuye a la actual situación del UCS. La elección del período de análisis, extendido aproximadamente desde finales de junio de 2021 hasta mayo de 2022, se justifica porque es el de cierre más reciente al inicio de este trabajo.

La estructura sucesiva del documento da cuenta de los siguientes apartados: 2) contexto geográfico, antecedentes, y delimitación de clases de UCS; 3) materiales; 4) métodos; 5) resultados - discusiones; y 6) conclusiones.

En el segundo apartado se describen las principales características biofísicas y socioeconómicas que explican la distribución reciente del UCS en Uruguay. Los antecedentes incluyen literatura científica centrada en la interpretación de series multitemporales para la elaboración de cartografía de UCS. La revisión del contexto geográfico y de estos antecedentes proporciona el sustento para definir las categorías de UCS objeto de representación. En “materiales”, se detallan los datos de entrada y se justifica el uso de las tecnologías GeoBD elegidas. En “métodos” se exponen los procedimientos para la construcción del conjunto de datos temporal (JDT, por sus siglas en inglés), el entrenamiento, el ajuste de los hiperparámetros (HPT, por sus siglas en inglés), la creación de una máscara para aislar vegetación en zonas urbanas, así como los procesos de clasificación supervisada y la validación correspondiente. En “resultados – discusiones”, se presentan los valores para el ajuste de HPT y los dos mapas obtenidos a partir de las combinaciones de JDT y clasificador. Se calculan las estadísticas de superficie y fiabilidad para discutir las principales fortalezas y limitaciones de cada

producto. Finalmente, dentro de las conclusiones y recomendaciones, es valorada la experiencia y son sugeridas pautas que posiblemente optimicen los resultados en futuras ocasiones.

2. Contexto geográfico, antecedentes y delimitación de clases

2.1. Contexto geográfico

Uruguay cuenta con una superficie continental próxima a los 176 215 km² y se localiza entre los 30° - 35°S y los 53° - 58°O (Figura 1). El Instituto Uruguayo de Meteorología (2022) señala que, según la categorización climática de Köppen, el país presenta un clima templado, moderado y lluvioso, identificado como tipo "C". Posee una temperatura húmeda en general, marcada como tipo "f", donde el valor del mes más cálido supera los 22°C. La precipitación se distribuye de modo relativamente uniforme durante las cuatro estaciones, aunque se aprecian marcadas diferencias a nivel regional. Por ejemplo, se alcanzan valores máximos de 1500 mm hacia el norte del Río Negro y mínimos de 1100 mm al sur.




Figura 1. Situación relativa del Uruguay

A nivel topográfico, Panario *et al.* (2011) sostienen que las geoformas predominantes son las planicies y lomadas, dado que comprenden alrededor de un 84.9 % del territorio. En orden de importancia, siguen las colinas (13.4 %), los cerros (1.4 %) y las depresiones cerradas o abiertas (0.4 %). Existe una densa red fluvial compuesta por ríos, arroyos, lagunas costeras y lagos artificiales como tajamares y represas (Conde *et al.* 2002). En su totalidad, el país pertenece al bioma denominado “pastizales pampeanos” o “pastizales del Río de la Plata” (Soriano 1992). Estos, son ecosistemas caracterizados por la presencia de un estrato herbáceo dominado por especies de pastos o gramíneas, que pueden estar acompañados por una vegetación leñosa variable (Sala y Paruelo 1997), dentro de la cual destacan las perennifolias autóctonas que localmente se conocen como “monte nativo”.

Dentro del plano socioeconómico, en 2021, el país contaba con una cantidad próxima a los 3 426 260 habitantes (The World Bank 2022), quienes se distribuían en 4 % para el ámbito rural y 96 % en lo urbano. Se presenta una marcada concentración hacia el Área Metropolitana de Montevideo - zona costera. En lo económico, se subraya una sólida base agrícola – forestal que se respalda en las citadas condiciones biofísicas y en la ejecución de instrumentos político – legales (Paruelo *et al.* 2006) que fomentaron el aumento de las superficies destinadas a los cultivos y las plantaciones forestales (Arbeletche y Gutiérrez 2010).

2.2. Antecedentes

El UCS del Uruguay ha sido cartografiado desde esfuerzos centrados en lo local o en lo global. Como antecedentes (Tabla 1), se cuenta con varias referencias documentadas en la literatura científica y en estas, se hallan tres cuestiones clave: 1) Los herbazales, el monte nativo, las forestaciones, los espacios agrícolas, los cuerpos de agua y las áreas urbanas son las clases generales más relevantes. 2) La cartografía con mayor resolución espacial se basa en S2 (10 m), y trata de productos globales. Las propuestas que parten de Landsat (30 m) alcanzan la mayor desagregación a nivel de clases. 3) Para los trabajos publicados entre 2021 y 2022, sobresale el procesamiento de grandes volúmenes de datos que fueron hallados y procesados mediante HPC de acceso abierto en GEE (Gorelick *et al.* 2017) o Microsoft Planetary Computer (Microsoft Open Source *et al.* 2022).

Tabla 1. Algunas referencias de cartografía del UCS inherentes el área de estudio

Autores y fecha	Período de análisis	Datos de entrada	Clases
Baeza <i>et al.</i> (2022)	Mapas anuales. 2001 - 2018.	Se obtuvieron datos de los sensores Landsat Thematic Mapper (TM), Enhanced Thematic Mapper Plus (ETM+) y Operational Land Imager y Thermal Infrared Sensor (OLI-TIRS). Las colecciones de imágenes fueron procesadas a través de GEE.	Formación forestal natural cerrada (bosques), formación forestal natural abierta (sabana), plantación forestal, humedal, pastizales, área agropecuaria (incluye cultivos y pasturas implantadas), área no vegetada, ríos, lagos, océanos y no observado.
Brown <i>et al.</i> (2022)	Desde junio de 2015 hasta el presente.	En el marco del proyecto Dynamic World (DW) son clasificadas imágenes satelitales S2 mediante Deep Learning. La cartografía resultante representa un horizonte temporal y contexto espacial definidos por el usuario. Los autores contaron con GEE para el tratamiento de las imágenes.	Cuerpos de agua, cubiertas arbóreas, herbazales, cultivos, matorral - arbustos, áreas construidas, y suelo descubierto.
Karra <i>et al.</i> (2021)	Mapas anuales desde 2017 hasta 2022.	Se dispuso de series temporales S2 que fueron clasificadas mediante soluciones de IA. El procesamiento tuvo lugar en la plataforma Microsoft Planetary Computer. El producto se conoce como S2 10 meter Land Use/Land Cover.	Cuerpos de agua, cultivos agrícolas, vegetación arbórea, áreas construidas, cobertura nubosa, vegetación inundada, suelo desnudo, y pastizales.
Baeza <i>et al.</i> (2014)	Desde mayo de 2011 hasta marzo de 2012.	Series temporales del Índice de Vegetación de Diferencia Normalizada (NDVI) obtenido a partir de imágenes del Moderate-Resolution Imaging Spectroradiometer (MODIS), datos de campo e imágenes TM o ETM+.	Recursos forrajeros perennes, forestación y monte, cultivos de verano y doble cultivo.

2.3. Delimitación de clases

Se definen trece clases de entornos naturales, agrícolas y urbanos. Para entender los alcances y limitaciones de cada caso, se formula la descripción correspondiente.

- Cuerpos de agua (Ca): comprende masas continentales de origen natural (p. ej. lagunas costeras) o artificial (p. ej. embalses y tajamares).
- Herbazales – mezcla de herbazales (Hbm): incluye espacios de vegetación herbácea natural o aquella que, estando destinada para propósitos agrícolas como el pastoreo, posee un comportamiento espectral que asemeja a la natural. Del mismo modo, comprende herbazales con proporciones de vegetación leñosa que no pueden diferenciarse debido a la resolución espacial de los sensores S1 y S2. Por último, se incluyen herbazales pos siembra que se encuentran mezclados con restos secos de materia vegetal proveniente de cosechas. La dificultad para diferenciar entre herbazales de uso agrícola y herbazales naturales es una restricción en esta categoría. Ello limita una clasificación más pormenorizada desde el criterio del uso del suelo.
- Monte nativo (Mn): comprende una asociación heterogénea de especies arbóreas que se desarrollan sin la intervención humana. El conjunto abarca bosques diferenciables según su posición topográfica o proximidad a los cursos de agua: ribereños, de parque, de quebrada, serranos, palmares y psamófilos.
- Forestaciones y bosques plantados (Fs): se compone principalmente de cultivos de eucaliptos y pinos destinados a su explotación económica. También abarca vegetación arbórea plantada como los denominados 'montes de abrigo y sombra', así como los bosques costeros. Los primeros proporcionan refugio al ganado durante episodios de intensas precipitaciones o elevada radiación solar, mientras que los segundos fueron mayoritariamente plantados en la zona costera oriental, con fines de restauración ecológica, protección ambiental y, en menor medida, con planes paisajísticos.
- Cosecha de forestación (Cf): como producto de la remoción de las especies maderables que crecen en las forestaciones, esta clase representa la transición de cultivos forestales hacia suelo desnudo.
- Vegetación sujeta a regímenes de inundación (Huv): se trata de áreas vegetadas que están saturadas o inundadas permanente o intermitentemente. En la clase pueden incluirse humedales aledaños a marismas, charcas, lagos, ríos, llanuras de inundación y pantanos. Entre los humedales costeros hay marismas de agua salada, estuarios, manglares, albuferas e incluso arrecifes de coral. Dadas las circunstancias, es posible que en la clasificación supervisada, espacios correspondientes a Huv sean confundidos con cubiertas vegetales como Hbm o Mn.
- Cultivos de invierno (Ci): por lo general se siembran entre abril a junio, en tanto que la cosecha tiene lugar entre septiembre y noviembre. Su evolución inicia con la siembra, fase en la que el sustrato tiende a comportarse espectralmente como suelo desnudo. Durante el crecimiento de la planta, se presentan distintos estadios de vegetación vigorosa en función del manejo, características agronómicas del cultivo e inclusive, condiciones ambientales asociadas a la precipitación. Finalizada la cosecha y como resultado de la remoción de la cubierta vegetal; el sustrato puede asemejar al suelo desnudo o a una mezcla de este con restos de materia vegetal seca. Los sembradíos de trigo, cebada, avena, alfalfa y colza son destacados ejemplos.
- Cultivos de verano (Cv): habitualmente se siembran entre septiembre y diciembre de cada año, con la cosecha programada para el periodo comprendido entre marzo y junio del año calendario siguiente (Camarota y Natale 2019). Salvando las evidentes diferencias entre los periodos de siembra y cosecha, los CV presentan una evolución similar a los Ci. El arroz, la soja, el maíz, la papa, el girasol, el sorgo y la caña de azúcar son ejemplos representativos.
- Cultivos anuales o doble cultivo (Dc): durante la totalidad o una considerable parte del AAG, estos espacios se hallaban provistos de biomasa vegetal que corresponde a un mismo cultivo o

rotaciones de estos. Lo primero se ejemplifica con las especies forrajeras destinadas para la alimentación del ganado; mientras que lo segundo, con rotaciones como la del trigo o la soja.

- Transiciones entre suelo desnudo o afloramientos rocosos y gramíneas (Sda): son espacios provistos de suelo desnudo o afloramientos rocosos durante la totalidad o mayor parte del AAG. Las gramíneas están presentes como resultado de la sucesión natural.
- Tejido urbano, zonas industriales y construcciones rurales (Tuz): comprende los tejidos urbanos continuo y discontinuo. También se incluyen las zonas industriales, las construcciones rurales, los aeropuertos y las canteras.
- Vegetación en zonas urbanas (Vhu): son zonas vegetadas de origen preferentemente artificial en contextos urbanos.
- Dunas y acumulaciones de arena (Dac): trata de los arcos de playas arenosas y los cordones dunares que se distribuyen a lo largo de la costa marítima. También se incluyen las barras de arena próximas a los cursos de agua.

3. Materiales

3.1. Los datos

Al inicio del estudio, S1 y S2, contaban respectivamente con dos satélites operativos: S1A y S1B en el caso de la primera, y S2A y S2B en el de la segunda. Esta actividad conjunta, permitía una frecuencia de adquisición, con resoluciones temporales de hasta 6 días para S1 y 5 días para S2. La elección de los ARD S1 (S1GRD) y S2 (S2L2A) como datos de entrada, se fundamenta en su viable complementariedad para la cartografiar el UCS mediante series temporales densas (Orynbaikyzy *et al.* 2020, Chakhar *et al.* 2021).

S1GRD se genera a partir de un sistema que opera en la banda C, frecuencia de 5.405 GHz. Según el cronograma de captura por zona geográfica, es posible adquirir imágenes según los nodos ascendente o descendente, y en las polarizaciones Horizontal – Horizontal (HH), Horizontal – Vertical (HV), Vertical – Vertical (VV) o Vertical – Horizontal (VH). Los datos se expresan en decibeles (dB) y fueron sujetos a un preprocesamiento que incluyó la eliminación del ruido térmico, la calibración radiométrica y la corrección geométrica mediante proyección al elipsoide WGS84. La resolución espacial es de 10 m.

S2L2A proporciona imágenes en los espectros visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR) con resoluciones espaciales de 10 m o 20 m, según la banda espectral. Las franjas B2 (azul), B3 (verde), B4 (rojo) y B8 (NIR) proveen una resolución espacial de 10 m. Las bandas B5 (Red Edge 1), B6 (Red Edge 2), B7 (Red Edge 3), B8A (Red Edge 4), B11 (SWIR 1) y B12 (SWIR 2) ofrecen una resolución espacial de 20 m. Los datos contienen valores de reflectancia a nivel de superficie y fueron corregidos atmosféricamente mediante la eliminación de efectos de dispersión provocados por gases, especialmente ozono, oxígeno y vapor de agua. S2L2A también incluye datos a 60 m de resolución espacial: B1 (aerosoles costeros), B9 (vapor de agua) y B10 (cirros); no obstante, estas se restringen para facetas de corrección.

3.2. Los recursos informáticos

Los recursos informáticos engloban la plataforma GEE, el paquete GEEMAP (Wu 2020), los clasificadores RF (Breiman 2001) y SVM (Cortés y Vapnik 1995), así como la librería GridSearchCV (GCV) del paquete Scikit-learn (Pedregosa *et al.* 2011).

GEE es un recurso para la búsqueda y procesamiento eficiente de grandes volúmenes de datos adquiridos por reconocidos programas para la observación de la tierra (como Landsat, Terra y Sentinel) y su manejo es adecuado para la producción de cartografía de UCS (Shelestov *et al.* 2017, Amani *et al.* 2020). GEE permite operar desde JavaScript o Python. Mientras que la primera opción se gestiona de manera exclusiva a través de la interfaz web, Python ofrece una mayor versatilidad al ser ejecutable localmente o en línea. Además, mediante Python, es posible integrar bibliotecas o paquetes externos a GEE en el entorno de trabajo, lo cual amplía las posibilidades para ejecutar análisis según

requerimientos puntuales. Dada la ventaja, se decide operar con Python mediante la biblioteca GEEMAP, a fin de aprovechar las funcionalidades de GCV, como se describe en el párrafo siguiente.

RF y SVM se eligen debido a su extensa utilización en la literatura científica (Sheykhmousa *et al.* 2020) y por ser competitivos (Adugna *et al.* 2022) para la clasificación de imágenes satelitales. En conexión a ello, diversos estudios (Venter y Sydenham 2021, Vizzari 2022, Billah *et al.* 2023) reconocen la eficacia de RF para cartografiar UCS mediante grandes volúmenes de datos S1 y S2. En un contexto similar, las virtudes de SVM son subrayadas por Brinkhoff *et al.* (2019), y Yang *et al.* (2021). RF genera múltiples árboles de decisión, proporcionando un modelo más robusto en comparación con lo que podría lograrse con cada árbol de forma individual. RF puede manejar importantes cantidades de predictores (datos ópticos, NDVI y canales SAR para el caso) en la clasificación supervisada (Cánovas-García *et al.* 2017). SVM es un clasificador tipo Kernel capaz de transformar datos de un espacio a otro de mayores dimensiones para crear hiperplanos que faciliten la identificación de patrones (Microsoft 2023), que maximicen la separación entre clases (Melgani y Bruzzone 2004). La dimensión está dada por el número de bandas incorporadas en el análisis, el hiperplano es el límite de decisión para separar las clases, y los vectores de soporte son un subconjunto de observaciones de entrenamiento que definen la ubicación del hiperplano de separación (MathWorks 2023).

Un óptimo aprovechamiento de RF y SVM comprende la configuración de sus respectivos hiperparámetros (HIP) mediante el proceso conocido como "ajuste de los hiperparámetros" (HPT). Básicamente, este se centra en crear combinaciones de HIP (modelos) para identificar la opción que arroje el desempeño más adecuado (Mohd *et al.* 2020, Amazon Web Services 2023). Elgeldawi *et al.* (2022) sostienen que HPT puede ejecutarse mediante técnicas como Random Search, Bayesian Optimization, Particle Swarm Optimization, Genetic Algorithm y Grid Search. La última es operable en GCV y es la elección para este trabajo. Su operatividad se basa en la delimitación por parte del usuario, de un conjunto de alternativas para HIP. Posteriormente, en una rejilla (o grid), se generan todos los posibles modelos, evaluándose el rendimiento para identificar la solución más adecuada.

4. Métodos

4.1. Desarrollo del JDT

Para las subsiguientes clasificaciones con RF y SVM, el desarrollo del JDT implica crear un archivo que integre S1GRD y S2L2A. Ello conlleva a generar series temporales densas (Anaya *et al.* 2023) que son óptimas para cartografiar el UCS (Suchen 2023). Las mismas son adecuadas para lograr cotas de exactitud superiores en comparación con clasificaciones basadas exclusivamente en productos ópticos o SAR (Steinhausen *et al.* 2018). Este desarrollo se implementa a través de las siguientes subfases:

4.1.1. Selección de las bandas y aplicación de filtros temporales

Para el área de estudio y a la fecha, las adquisiciones S1 se limitaban a las polarizaciones VH y VV en el nodo descendente. En consecuencia, se utilizaron los canales S1GRD contentivos de las opciones disponibles. Para incorporar S2L2A en los espectros visible, NIR y SWIR, se seleccionaron B4, B8 y B11 con cobertura nubosa igual o inferior al 10 %.

Se aplican filtros para organizar conjuntos temporales según las siguientes pautas de captura:

- S1GRD para cada uno de los meses desde julio de 2021 hasta mayo de 2022.
- S2L2A para los intervalos variables: 1/7/2021-10/8/2022 (IV1); 16/9/2021-15/11/2021 (IV2); 16/11/2021-15/1/2022 (IV3); 16/1/2022-15/3/2022 (IV4); y 16/3/2022-30/5/2022 (IV5). Estas fechas eran los períodos más acotados para abarcar consistentemente toda el área de estudio, según ventanas predominantemente acordes con las estaciones de invierno, primavera, verano y otoño del hemisferio sur.

Después de aplicar los filtros, se identificó el total de imágenes disponibles para S1GRD (Tabla 2) y S2L2A (Tabla 3). Es evidenciado un mayor total general de registros ópticos (1178) en

comparación con el total para el SAR (432). En esencia, el contraste subyace en la cobertura espacial de cada imagen: S1GRD posee un ancho de franja cercano a los 250 km, correspondiente al modo Interferometric Wide Swath (IW), que es el habitualmente empleado para el monitoreo terrestre. En cambio, los productos S2L2A se distribuyen en imágenes de aproximadamente 110 km × 110 km, lo cual implica una cobertura menor. En ambos casos, las dimensiones pueden variar.

Tabla 2. Total de imágenes S1GRD según mes y año de captura

Año Mes	2021							2022				Total general
	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar	Abr	May	
Total parcial	44	50	43	50	49	40	32	33	27	31	33	432

Tabla 3. Total de imágenes S2L2A según intervalo variable de captura

Intervalo variable	IV1	IV2	IV3	IV4	IV5	Total general
Total parcial	140	279	280	219	260	1178

En el caso de los datos de microondas, se observa que entre julio y diciembre de 2021 hubo una tendencia mensual estable de aumento y disminución en el número de registros, lo cual es coherente con un funcionamiento programado del sensor y de la plataforma satelital. Sin embargo, este número se redujo en fechas posteriores, debido al cese de operaciones del S1B, reportado por la Agencia Espacial Europea (ESA) el 23 de diciembre de 2021 (ESA, 2022). El incidente se atribuyó a una falla en los sistemas electrónicos responsables de suministrar energía a la plataforma espacial.

Para S2L2A, la disponibilidad más baja de imágenes (140) se registró en IV1, correspondiente al invierno austral. En contraste, IV2 e IV3, que abarcan parcialmente la primavera y el verano, respectivamente, presentaron la mayor cantidad de registros, con 279 y 280 imágenes. En los periodos siguientes, IV4 (verano) e IV5 (verano-otoño), se identificaron 219 y 260 capturas, en ese orden. Para los subsiguientes procesos de clasificación supervisada, esta disponibilidad podría repercutir en ventajas para distinguir clases preponderantemente influenciadas por la estación estival (por ejemplo, los Cv) y, al mismo tiempo, impactar en desafíos para discriminar categorías influenciadas durante el invierno (por ejemplo, Ci y Dc).

4.1.2. Creación de los compuestos temporales de mediana

Para cada uno de los conjuntos temporales definidos en 4.1.1, se calcula el valor de la mediana sobre los píxeles de una misma ubicación (x, y). Diversas iniciativas (Zeng *et al.* 2020, Rafif *et al.* 2021, Asam *et al.* 2022) comprobaron que este procedimiento es adecuado para generar una imagen con reducción de ruido y valores atípicos. Como resultado, se obtienen: a) once compuestos de mediana para VH y otros once para VV, correspondientes a cada uno de los meses considerados (Tabla 4); y b) cinco compuestos ópticos de mediana asociados a los intervalos variables (Tabla 5). En el caso de los últimos, el procedimiento se documenta como apropiado para restringir la aparición de píxeles con algunos valores extremos, y que son distintivos de las densas coberturas nubosas o de las sombras que éstas producen (Digital Earth Africa 2020).

Tabla 4. Compuestos SAR de mediana según mes y polarización

Mes	Compuestos	
	VH	VV
Julio	VHjul	VVjul
Agosto	VHago	VVago
Septiembre	VHsep	VVsep
Octubre	VHoct	VVoct
Noviembre	VHnov	VVnov
Diciembre	VHdic	VVdic

Enero	VHene	VVene
Febrero	VHfeb	VVfeb
Marzo	VHmar	VVmar
Abril	VHabr	VVabr
Mayo	VHmay	VVmay

Tabla 5. Compuestos ópticos de mediana según intervalos y bandas

Compuesto	B4	B8	B11
IV1	IV1B4	IV1B8	IV1B11
IV2	IV2B4	IV2B8	IV2B11
IV3	IV3B4	IV3B8	IV3B11
IV4	IV4B4	IV4B8	IV4B11
IV5	IV5B4	IV5B8	IV5B11

4.1.3. Cálculo del NDVI mediano

A partir de las bandas medianas del rojo y del NIR generadas en el apartado 4.1.2 (Tabla 5), y utilizando la propuesta de Rouse *et al.* (1974), se calcula el Índice de Vegetación de Diferencia Normalizada (NDVI) correspondiente a los compuestos IV1, IV2, IV3, IV4 e IV5 (Tabla 6).

Tabla 6. Cálculo de los compuestos NDVI según su intervalo

Compuesto NDVI	Cálculo
IV1NDVI	$(IV1B8 - IV1B4) / (IV1B8 + IV1B4)$
IV2NDVI	$(IV2B8 - IV2B4) / (IV2B8 + IV2B4)$
IV3NDVI	$(IV3B8 - IV3B4) / (IV3B8 + IV3B4)$
IV4NDVI	$(IV4B8 - IV4B4) / (IV4B8 + IV4B4)$
IV5NDVI	$(IV5B8 - IV5B4) / (IV5B8 + IV5B4)$

4.1.4. Creación de un archivo de canales, bandas e índices intercalados

A partir de los productos descritos en los apartados 4.1.2 y 4.1.3, se genera un archivo que integra de forma intercalada los canales, bandas e índices. Este archivo constituye la base del JDT (Figura 2) y, en adelante, será referido como S1S2opc.

**Figura 2. La conformación del JDT**

4.2. Entrenamiento

Con base en la interpretación visual iterativa de los cinco compuestos ópticos de mediana según combinación RGB B4/B8/B11, se digitalizan 3252 polígonos que se destinaron para el entrenamiento. De esta forma se generan las etiquetas por clase (las tipologías de UCS) con los valores de los predictores (canales, bandas e índices contenidos en S1S2opc) según píxel.

4.3. HPT

Dado que la investigación se centra en la clasificación del archivo S1S2opc mediante RF y SVM, resulta fundamental identificar el modelo más eficiente en cada caso. A estos modelos se los denominará, respectivamente, S1S2opcRF y S1S2opcSVM. La identificación se lleva a cabo mediante dos subfases: la propuesta de alternativas de HIP y la validación cruzada.

4.3.1. Propuesta de alternativas de HIP

Se proponen distintas opciones (Tabla 7) que surgen de considerar lo referido por Sonobe y otros (2014), Belgiu y Drăguț (2016) y Shetty (2019) para generar mapas de UCS a partir de imágenes satelitales clasificadas con RF o SVM.

Tabla 7. Referencias de hiperparámetros según clasificador

Clasificadores	Hiperparámetros	Alternativas
RF	Number of trees	100, 144, 188, 233, 277, 322, 366, 411, 455, 500
	Variables per split	2, 3, 4, 5
	Min leaf population	1, 2
SVM	Kernel type	Polynomial, Radial Basis Function (RBF)
	Cost	1, 5, 10
	Gamma	0.1, 1, 1.5

4.3.2. Validación cruzada

Las alternativas de HIP y las etiquetas generadas en 4.2 se disponen para ejecutar la validación cruzada. La puesta a punto del proceso se realiza a través de la técnica k-fold Cross Validation (opción por defecto en GCV), siguiendo los pasos descritos a continuación:

- Se dividen los registros en k particiones (*k-folds*). Se opta por $k = 10$.
- Se ejecuta un bucle con k iteraciones, en cada una de las cuales se selecciona uno de los *k-folds* como conjunto de prueba, mientras que los restantes se disponen para crear el modelo.
- En cada iteración, se entrena el modelo con $k-1$; mientras que el rendimiento se evalúa con la partición excluida. Se dispone de la precisión (%) como métrica de rendimiento.
- Después de completar las iteraciones, se promedian los resultados de rendimiento obtenidos en cada una de las iteraciones.

4.4. Creación de una máscara para Vhu

Con la data vectorial que modela la cobertura del Sistema Urbano Nacional (Ministerio de Vivienda y Ordenamiento Territorial, 2023), se crea una máscara para que la clasificación de Vhu se restrinja a entornos urbanos.

4.5. Clasificación supervisada

Establecidas las combinaciones más adecuadas de HIP según JDT - clasificador, se ejecutan dos esquemas de clasificación: S1S2RF_uy y S1S2SVM_uy.

4.6. Validación de los productos

Este procedimiento consta del desarrollo de la BD de validación (BDV) y el cálculo de las matrices de confusión - estadísticas de fiabilidad. En cuanto a lo primero, se generaron 1659 polígonos a partir de tres fuentes independientes (Tabla 8): *Dynamic World* (DW), levantamientos en el terreno y el análisis visual de mosaicos mensuales PSScene de la constelación PlanetScope. Es oportuno remarcar:

- Desde DW se obtuvo el 47.80 % de BDV. Incluye Huv, Hbm, Ca, Mn, y Fs. Este recurso se descarta para cotejar las clases agrícolas porque el nivel de detalle temático es diferente al definido para este trabajo.
- Los levantamientos en el terreno tuvieron lugar en las principales regiones agrícolas del país; las cuales coinciden con las cuencas de los ríos Santa Lucía, Negro, Uruguay y de La Plata. La fuente comprende cerca del 17.66 % del total de la BDV e incluye fundamentalmente clases agrícolas.
- Apoyándose en la consulta a expertos y en criterios de interpretación visual como el contexto, el color, el tono, la textura, la forma y el tamaño; se obtiene un 34.54 % de las muestras. Esta tarea comprende todas las clases y se fundamenta en mosaicos mensuales PSScene correspondientes a junio 2021, julio 2021, enero 2022 y febrero 2022. Los productos se encontraban en combinación de color verdadero, ortorectificados, con 3 – 5 m de resolución espacial y con proyección UTM WGS84.

Tabla 8. Polígonos de validación según la fuente

Fuente	Número de polígonos	% respecto al total
DW	793	47.79
Levantamientos en el terreno	293	17.65
PSScene	573	34.53
Total	1 659	100

En la Figura 3 se observa la distribución espacial de los polígonos de validación. Los respectivos ejemplos de levantamientos en el terreno, DW y PSScene; se ejemplifican en las ventanas A), B), y C).




Figura 3. Distribución espacial de los datos de validación, según la fuente

Para c/u de los productos generados en 4.5, se desarrolla una matriz de confusión (Apéndice 1) para calcular el índice kappa, la exactitud general, la precisión del usuario (PU) y la precisión a nivel de productor (PP).


5. Resultados y discusión.

Los modelos más eficaces para cada clasificador logran niveles de precisión adecuados (Tabla 9). S1S2opcRF supera a S1S2opcSVM en aproximadamente un 7 %. Las alternativas de HIP que componen dichos modelos guiaron la implementación de la clasificación supervisada.

Tabla 9. Modelo más eficiente según clasificador y precisión (%)

JDT	Clasificador	Modelo	Precisión (%)
S1S2opc	RF	Number of trees: 277; Variables per Split: 2; Min leaf population: 1	0.927
	SVM	Kernel type: Polynomial; Cost: 1 ; Gamma: 0.01	0.857

Siguiendo los esquemas de clasificación pautados en 4.5; se generan los mapas S1S2RF_uy (Figura 4) y S1S2SVM_uy (Figura 5). Por medio de las matrices de confusión (Apéndice I), se calculan las estadísticas de fiabilidad, tanto las generales como las desglosadas por clase. Los resultados revelan que las primeras son más favorables para S1S2RF_uy, puesto que se alcanza una exactitud global de 83 % y un índice kappa de 0.81; que levemente superan los respectivos 81 % y 0.78 de S1S2SVM_uy. Dada la similitud de estos estadísticos, se determina que el primer mapa obtiene una fuerza de concordancia ligeramente superior.

**Figura 4. S1S2RF_uy**




Figura 5. S1S2SVM_uy

Basándose en los valores de proporción de superficie por clase (Figura 6) y las estadísticas de fiabilidad desglosadas por clase (Apéndice 2), se comentan las situaciones destacadas:

- Hbm es la categoría que ocupa la mayor proporción superficie. En ambos casos, comprende casi el 60 % del área de estudio. No se evidencian contrastes acusados entre las exactitudes según mapa ya que las PP y PU superan el 0.8.
- Alcanzando valores PU de 0.68 y PP de 0.76 para ambos mapas, Huv se confunde principalmente con Hbm y Mn. El efecto es particularmente localizado en las proximidades de cuerpos de agua cuya extensión varía por causas estacionales.
- Ca cubre cerca del 1.2 % del área de estudio y en ambos casos, logró elevados valores de PU y PP que superaron 0.9.
- Como un conjunto, las clases agrícolas (Cv, Ci y Dc) ocupan superficies que oscilan entre el 17.86 % y el 18.28 %. En general, las estadísticas de fiabilidad por clase son levemente más elevadas para S1S2opcRF. Los valores más idóneos de PP y PA (cerca de 0.8) se lograron para CV. Las principales confusiones surgen entre Ci y DC. El efecto es más acentuado en las zonas agrícolas de las cuencas del Río Santa Lucía y del Río Uruguay, regiones donde precisamente, es marcada la presencia de estos cultivos. Los hallazgos se respaldan con el trabajo de Mountrakis *et al.* (2022); quienes, por medio de una revisión sistemática, evidenciaron que la cartografía de DC conlleva desafíos debido a las limitaciones propias de las bandas espectrales para diferenciar sutiles variaciones de los picos de vegetación entre dos cultivos consecutivos. A este caso debe agregarse la dificultad de contar con series temporales más densas en el JDT.
- El mapa generado con SVM fue óptimo para identificar Tuz. Contrariamente, en el producto generado con RF es más recurrente la confusión de algunas infraestructuras propias de esta categoría (por ejemplo, red vial, pistas de aeropuertos y agrupaciones de construcciones dispersas) con Sda.

- Los aciertos relativos a Vhu corresponden con importantes conglomerados de vegetación presentes en espacios urbanos; mientras que los errores se atribuyen a las limitaciones propias de la resolución espacial de S1GRD y S2L2A.




Figura 6. Proporción de superficie según clase

Aunque el cálculo del píxel mediano a partir de conjuntos de imágenes ópticas se reconoce como una estrategia para generar compuestos libres de nubes, en este caso se identificó la presencia de formaciones nubosas en una ventana espacial acotada del compuesto IV1, localizada en el sector sur del país (Figura 7). Esta situación evidencia que la persistencia de cobertura nubosa es un desafío para la adquisición de imágenes ópticas en focos puntuales y durante el período invernal.

Considerando que se dispuso de un JDT desarrollado con múltiples entradas (cinco compuestos ópticos, cinco de NDVI y veintidós de SAR distribuidas equitativamente entre VH y VV), las cuales fueron clasificadas mediante RF y SVM, resulta pertinente reportar el impacto de estas formaciones en IV1 sobre los resultados. Se constató que S1S2RF_uy no fue afectado, mientras que en S1S2SVM_uy estas formaciones fueron erróneamente identificadas como Tuz para una superficie menor a 20 km² (Figura 7). No obstante, el efecto global de esta restricción se considera despreciable. Adicionalmente, el efecto instigó a explorar las causas subyacentes: un análisis preliminar sugiere que la mayor sensibilidad de SVM al ruido (para el caso, una leve fracción de cobertura nubosa en IV1) en comparación con algoritmos como RF (Mountrakis *et al*, 2011) habría influido en tal identificación. En consecuencia, el hiperplano de separación generado por SVM asignó erróneamente las coberturas nubosas residuales a la clase Tuz, probablemente porque ambas cubiertas presentan elevados valores de reflectancia en el espectro óptico.




Figura 7. La cobertura nubosa y sus efectos en S1S2SVM_uy

6. Conclusiones y recomendaciones

A partir de un JDT, se generaron dos mapas de UCS empleando RF y SVM, respectivamente. Esta es una de las primeras referencias documentadas en la literatura científica en las que se clasifica el UCS del Uruguay mediante el uso conjunto de S1 y S2. La experiencia confirma el potencial del GeoBD para un desarrollo ágil y adecuado de la cartografía del UCS que cubre todo el territorio del Uruguay a partir de imágenes de resolución espacial media – alta. En cuanto a los métodos, se destaca que el HPT fue un paso crítico para maximizar el rendimiento de los clasificadores, dado que estos derivaron en mapas cuyas estadísticas de fiabilidad fueron óptimas y bastante consistentes entre sí. Aunque se han demostrado los beneficios de utilizar compuestos basados en la mediana, es necesario tener en cuenta que este enfoque puede restringir la detección de variaciones temporales sutiles, como aquellas observables entre datos capturados en fechas continuas dentro del cronograma de adquisición de las imágenes. Estas diferencias pueden ser esenciales para distinguir determinados UCS con marcada variabilidad espectral en intervalos de tiempo relativamente acotados.

Si bien, el enfoque del AAG ha sido exitosa y recurrentemente aplicado para orientar el desarrollo de la cartografía de UCS del área de estudio, este podría tener limitaciones si se demandasen análisis más detallados a escala regional y temporal. Las prestaciones que en cuanto a resolución espacial y temporal que ofrecen S1 y S2, sientan la posibilidad de encarar estos desafíos. Por ejemplo, una escala regional viable sería la de las cuencas hidrográficas. Ello facilitaría la comprensión análisis de dinámicas suscitadas en ámbitos espaciales concretos, como, por ejemplo, el estudio de la distribución espacial de los cultivos de arroz en la Cuenca de la Laguna Merín. Un abordaje temporal alternativo al AAG (por ejemplo, orientado a estaciones específicas como el invierno o el verano) podría revelar patrones estacionales relevantes. Estos patrones no solo enriquecerían la comprensión del UCS, sino que también reforzarían el estudio de posibles afectaciones ambientales como pueden ser aquellas derivadas de prácticas agrícolas estacionales. Es crucial contar con algoritmos de detección y remoción de nubes adaptados y validados para el contexto geográfico local, y que sean compatibles con entornos como GEE. En este marco, superar esta limitación se presenta como una prioridad en la agenda de investigación y desarrollo.

Referencias

- Adugna, T., Xu, W., Fan, J. (2022). Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*, 14(3), 574. <https://doi.org/10.3390/rs14030574>
- Amani, M., Ghorbanian, A., Ahmadi, S., Kakooei, M., Moghimi, A., Mirmazloumi, S. *et al.* (2020). 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. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Amazon Web Services, (2023). *¿Qué es el ajuste de los hiperparámetros?*. [consultado 19-07-2023]. Disponible en <https://aws.amazon.com/es/what-is/hyperparameter-tuning/>
- Anaya, J., Rodríguez-Buriticá, S., Londoño, M. (2023). Clasificación de cobertura vegetal con resolución espacial de 10 metros en bosques del Caribe colombiano basado en misiones Sentinel 1 y 2. *Revista de Teledetección*, (61), 29-41. <https://doi.org/10.4995/raet.2023.17655>
- Arbeletche, P., Gutiérrez, G. (2010). Crecimiento de la agricultura en Uruguay: exclusión social o integración económica en redes. *Pampa (Santa Fe)*, (6), 113-138.
- Asam, S., Gessner, U., Almengor González, R., Wenzl, M., Kriese, J., Kuenzer, C. (2022). Mapping crop types of Germany by combining temporal statistical metrics of Sentinel-1 and Sentinel-2 time series with LPIS data. *Remote Sensing*, 14(13), 2981. <https://doi.org/10.3390/rs14132981>
- Baeza, S., Vélez-Martin, E., De Abelleira, D., Banhero, S., Schirmbeck, J. *et al.* (2022). Two decades of land cover mapping in the Río de la Plata grassland region: the MapBiomass Pampa initiative. *Remote Sensing Applications: Society and Environment*, 28, 100834. <https://doi.org/10.1016/j.rsase.2022.100834>

Baeza, S., Baldassini, P., Bagnato, C., Pinto, P., Paruelo, J. (2014). Caracterización del uso/cobertura del suelo en Uruguay a partir de series temporales de imágenes MODIS. *Agrociencia (Uruguay)*, 18(2), 95-105.

Belgiu, M., 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>

Billah, M., Islam, A., Bin, W., Rahman, R. (2023). Random forest classifications for landuse mapping to assess rapid flood damage using Sentinel-1 and Sentinel-2 data. *Remote Sensing Applications: Society and Environment*. 30,100947. <https://doi.org/10.1016/j.rsase.2023.100947>

Breiman, L. (2001). Random Forests. *Machine learning*, 45, 5-32.

Brinkhoff, J., Vardanega, J., Robson, A. (2019). Land cover classification of nine perennial crops using sentinel-1 and-2 data. *Remote Sensing*, 12(1), 96. <https://doi.org/10.3390/rs12010096>

Brown, C., Brumby, S., Guzder-Williams, B., Birch, T., Hyde, S. *et al.* (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific Data*, 9(1), 251. <https://doi.org/10.1038/s41597-022-01307-4>

Camarota, A., Natale, J. (2019). Análisis del modelo logístico de la Cooperativa Unión Rural de Flores con el fin de determinar los cuellos de botella y proponer alternativas de mejora. Trabajo Final de Grado para la obtención del título de Licenciada en Gestión Logística. Universidad Católica del Uruguay, Montevideo.

Cánovas-García, F., Alonso-Sarriá, F., Gomariz-Castillo, F., Oñate-Valdivieso, F. (2017). Modification of the random forest algorithm to avoid statistical dependence problems when classifying remote sensing imagery. *Computers & Geosciences*, 103, 1-11. <https://doi.org/10.1016/j.cageo.2017.02.012>

Chakhar, A., Hernández-López, D., Ballesteros, R., Moreno, M. (2021). Improving the accuracy of multiple algorithms for crop classification by integrating Sentinel-1 observations with Sentinel-2 data. *Remote Sensing*, 13(2), 243. <https://doi.org/10.3390/rs13020243>

Chuvieco, E. (2008). Teledetección ambiental: La observación de la Tierra desde el espacio (3.^a ed.). Ariel, Barcelona.

Conde, D., Arocena, R., Rodríguez-Gallego, L. (2002). Recursos acuáticos superficiales de Uruguay: ambientes algunas problemáticas y desafíos para la gestión (I y II). *Ambios*, 3(10), 5-9.

Cortés, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20 (3), 273–297. <http://doi.org/10.1007/BF00994018>

Costa, H., Benevides, P., Moreira, F. D., Moraes, D., Caetano, M. (2022). Spatially stratified and multi-stage approach for national land cover mapping based on sentinel-2 data and expert knowledge. *Remote Sensing*, 14(8), 1865. <https://doi.org/10.3390/rs14081865>

Dahhani, S., Raji, M., Hakdaoui, M., Lhissou, R. (2022). Land cover mapping using Sentinel-1 time-series data and machine-learning classifiers in agricultural Sub-Saharan landscape. *Remote Sensing*, 15(1), 65. <https://doi.org/10.3390/rs15010065>

Darem, A., Alhashmi, A., Almadani, A., Alanazi, A., Sutantra, G. (2023). Development of a map for land use and land cover classification of the Northern Border Region using remote sensing and GIS. *The Egyptian Journal of Remote Sensing and Space Science*, 26(2), 341-350. <https://doi.org/10.1016/j.ejrs.2023.04.005>

Digital Earth Africa. (2020). Introduction to cloud-free composites. https://training.digitalearthafrika.org/en/latest/session_3/01_intro_composites.html

Dwyer, J., Roy, D., Sauer, B., Jenkerson, C., Zhang, H., Lymburner, L. (2018). Analysis ready data: enabling analysis of the Landsat archive. *Remote Sensing*, 10(9), 1363. <https://doi.org/10.3390/rs10091363>

- Elgeldawi, E., Sayed, A., Galal, A., Zaki, A. (2022). Hyperparameter tuning for machine learning algorithms used for arabic sentiment analysis. *Informatics*, 8(4), 79. <http://dx.doi.org/10.3390/informatics8040079>
- ESA. (2022). Mission ends for Copernicus Sentinel-1B satellite. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1/Mission_ends_for_Copernicus_Sentinel-1B_satellite
- Gomes, V., Queiroz, G., Ferreira, K. (2020). An overview of platforms for big earth observation data management and analysis. *Remote Sensing*, 12(8), 1253. <https://doi.org/10.3390/rs12081253>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., 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>
- IBM. (2022). ¿Qué es la computación de alto rendimiento (HPC)? [consultado 05-07-2023]. Disponible en <https://www.ibm.com/es-es/topics/hpc>
- Instituto Uruguayo de Meteorología. (2022). [consultado 04-11-2022]. Disponible en: <https://www.inumet.gub.uy/clima/estadisticas-climatologicas/clasificacion-climatica>
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J., Mathis, M., Brumby, S. (2021). Global land use/land cover with Sentinel 2 and deep learning. En 2021 IEEE international geoscience and remote sensing symposium IGARSS (4704-4707).
- Lambin, E., Turner, B., Geist, H., Agbola, S., Angelsen, A., Bruce, J. *et al.* (2001). The causes of land-use and land-cover change: moving beyond the myths. *Global environmental change*, 11(4), 261-269. [https://doi.org/10.1016/S0959-3780\(01\)00007-3](https://doi.org/10.1016/S0959-3780(01)00007-3)
- Lillesand, T., Kiefer, R., Chipman, J. (2003) Remote Sensing and Image Interpretation. (5ta ed). Wiley, New York.
- Mahlayeye, M., Darvishzadeh, R., Nelson, A. (2022). Cropping patterns of annual crops: a remote sensing review. *Remote Sensing*, 14(10), 2404. <https://doi.org/10.3390/rs14102404>
- MathWorks. (2023). Support Vector Machine. [consultado 20-07-2023]. Disponible en <https://la.mathworks.com/discovery/support-vector-machine.html>
- Melgani, F., Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42 (8), 1778-1790. <https://doi.org/10.1109/TGRS.2004.831865>
- Meyer, W., Turner, B. (1992). Human population growth and global land-use/cover change. *Annual review of ecology and systematics*, 23(1), 39-61.
- Microsoft. (2023). Componente Máquina de vectores de soporte de dos clases. [consultado 20 -07-2023]. Disponible en <https://learn.microsoft.com/es-es/azure/machine-learning/component-reference/two-class-support-vector-machine?view=azureml-api-2>
- Microsoft Open Source., Mc Farland, M., Emanuele, R., Augspurger, T. (2022). Microsoft Planetary Computer. *Zenodo*. <https://doi.org/10.5281/zenodo.7261897>
- Ministerio de Vivienda y Ordenamiento Territorial. (2023). Sistema de Información Territorial. [consultado 20 -07-2023]. Disponible en: <https://sit.mvot.gub.uy/sit/>
- Mohd, M., Abdul, A., Muazu, R., Taha, Z., Susto, G., Mukai, Y. (2020). Hyperparameter tuning of the model for hunger state classification. En *machine learning in aquaculture. springer briefs in applied sciences and technology*. Springer, Singapore. https://doi.org/10.1007/978-981-15-2237-6_5
- Mountrakis, G., Im, J., Ogole, S. (2011). Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* 2011, 66, 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>

- Nasiri, V., Deljouei, A., Moradi, F., Sadeghi, S., Borz, S. (2022). Land use and land cover mapping using Sentinel-2, Landsat-8 satellite images, and Google Earth Engine: a comparison of two composition methods. *Remote Sensing*, 14(9), 1977. <https://doi.org/10.3390/rs14091977>
- Orynbaikyzy, A., Gessner, U., Mack, B., Conrad, C. (2020). Crop type classification using fusion of Sentinel-1 and Sentinel-2 data: Assessing the impact of feature selection, optical data availability, and parcel sizes on the accuracies. *Remote Sensing*, 12(17), 2779. <https://doi.org/10.3390/rs12172779>
- Panario, D., Gutiérrez, O., Achkar, M., Bartesaghi, L., Ceroni, M. (2011). Clasificación y mapeo de ambientes de Uruguay. Informe Técnico. Universidad de La República, Montevideo.
- Paruelo, J., Guerschman, J., Pineiro, G., Jobbagy, E., Verón, S., Baldi, G., Baeza, S. (2006). Cambios en el uso de la tierra en Argentina y Uruguay: marcos conceptuales para su análisis. *Agrociencia Uruguay*, 10(2), 47-61.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. *et al.* (2011). Scikit-learn: Machine learning in Python. *The Journal of machine Learning research*, 12, 2825-2830.
- Rafif, R., Kusuma, S., Saringatin, S., Nanda, G., Wicaksono, P., Arjasakusuma, S. (2021). Crop intensity mapping using dynamic time warping and machine learning from multi-temporal PlanetScope data. *Land*, 10(12), 1384. <https://doi.org/10.3390/land10121384>
- Rouse, J., Haas, R., Schell, J., Deering, D. (1974) Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS-1 Symposium NASA, NASA SP-351, Washington DC, 309-317.
- Sala, O., Paruelo, J. (1997). Ecosystem services in grasslands. *Nature's services: societal dependence on natural ecosystems*, 237-251.
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A., Skakun, S. (2017). Exploring Google Earth Engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, 17. <https://doi.org/10.3389/feart.2017.00017>
- Shetty, S. (2019). Analysis of machine learning classifiers for LULC classification on Google Earth Engine. Tesis para la obtención del título de Maestría en Ciencias de la Geo-información y Observación de la Tierra. Universidad de Twente, Enschede.
- Sheykhoumousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: a meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325. <http://doi.org/10.1109/JSTARS.2020.3026724>
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N., & Shimamura, H. (2014). Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. *Remote Sensing Letters*, 5(2), 157-164. <https://doi.org/10.1080/2150704X.2014.889863>
- Soriano, A. (1992). Río de la Plata grasslands. *Natural grasslands: introduction and western hemisphere*, 367-40.
- Steinhausen, M., Wagner, P., Narasimhan, B., Waske, B. (2018). Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *International journal of applied earth observation and geoinformation*, 73, 595-604. <https://doi.org/10.1016/j.jag.2018.08.011>
- Suchen, X., Wu, X., Linlin, R., Wenqi, C., Jingnan, D. (2023) Assessment of ensemble learning for object-based land cover mapping using multi-temporal Sentinel-1/2 images, *Geocarto International*, 38 (1). <https://doi.org/10.1080/10106049.2023.2195832>
- Sun, L., Schulz, K. (2015). The improvement of land cover classification by thermal remote sensing. *Remote Sensing*, 7(7), 8368-8390. <https://doi.org/10.3390/rs70708368>
- The World Bank. (2022). Uruguay. [consultado 24-10-2022]. Disponible en <https://data.worldbank.org/country/uruguay?view=chart>

- United States Geological Survey. (2022). What is high performance computing? [consultado 24 -10-2022]. Disponible en: <https://www.usgs.gov/advanced-research-computing/what-high-performance-computing>.
- Venter, Z., Sydenham, M. (2021). Continental-scale land cover mapping at 10 m resolution over Europe (ELC10). *Remote Sensing*, 13(12), 2301. <https://doi.org/10.3390/rs13122301>
- Verburg, P., Neumann, K., Nol, L. (2011). Challenges in using land use and land cover data for global change studies. *Global change biology*, 17(2), 974-989. <https://doi.org/10.1111/j.1365-2486.2010.02307.x>
- Vizzari, M. (2022). PlanetScope, Sentinel-2, and Sentinel-1 data integration for object-based land cover classification in Google Earth Engine. *Remote Sensing*, 14(11), 2628. <https://doi.org/10.3390/rs14112628>
- Wagemann, J., Siemen, S., Seeger, B., Bendix, J. (2021). Users of open Big Earth data – an analysis of the current state. *Computers & Geosciences*, 157, 104916. <https://doi.org/10.1016/j.cageo.2021.104916>
- Wu, Q. (2020). Geemap: a Python package for interactive mapping with Google Earth Engine. *Journal of Open Source Software*, 5(51), 2305. <https://doi.org/10.21105/joss.02305>
- Wulder, M., Coops, N., Roy, D., White, J., Hermosilla, T. (2018). Land cover 2.0. *International Journal of Remote Sensing*, 39(12), 4254-4284. <https://doi.org/10.1080/01431161.2018.1452075>
- Yang, Y., Yang, D., Wang, X., Zhang, Z., Nawaz, Z. (2021). Testing accuracy of land cover classification algorithms in the qilian mountains based on gee cloud platform. *Remote Sensing*, 13(24), 5064. <https://doi.org/10.3390/rs13245064>
- Zeng, H., Wu, B., Wang, S., Musakwa, W., Tian, F., Mashimbye, Z. *et al.* (2020). A synthesizing land-cover classification method based on Google Earth Engine: a case study in Nzhelele and Levhuvu Catchments, South Africa. *Chinese Geographical Science*, 30, 397-409. <https://doi.org/10.1007/s11769-020-1119-y>

Apéndice 1. Matrices de confusión para las clasificaciones

A. Matriz de confusión S1S2RF_uy. Valores en píxeles.

Clases	Huv	Mn	Hbm	Cf	Ca	Ci	Cv	De	Fs	Tuz	Sda	Dac	Vhu	Total
Huv	300	63	33	6	0	4	8	3	11	0	5	0	9	442
Mn	2	520	0	0	0	0	0	0	52	0	0	0	0	574
Hbm	54	19	993	17	2	79	13	4	4	0	16	0	12	1213
Cf	0	0	0	340	0	0	0	0	19	0	0	0	0	359
Ca	27	0	0	0	349	0	0	0	0	0	0	0	0	376
Ci	0	0	29	0	0	752	51	188	0	0	12	0	0	1032
Cv	1	0	32	1	0	18	723	76	0	0	41	0	0	892
Dd	0	0	1	0	0	27	72	562	0	0	0	0	0	662
Fs	4	19	0	18	0	0	0	0	686	0	0	0	16	743
Tuz	0	0	1	0	0	0	0	0	0	99	25	6	2	133
Sda	5	0	4	0	0	40	0	4	0	0	215	4	0	272
Dac	0	0	0	0	0	0	0	0	0	0	0	173	0	173
Vhu	4	16	0	0	0	0	0	0	9	1	0	0	86	116
Total	397	637	1093	382	351	920	867	837	781	100	314	183	125	6987

B. Matriz de confusión S1S2SVM_uy. Valores en píxeles.

Clases	Huv	Mn	Hbm	Cf	Ca	Ci	Cv	Dc	Fs	Tuz	Sda	Dac	Vhu	Total
Huv	295	39	38	28	5	4	1	2	17	0	0	0	8	437
Mn	0	562	0	2	0	0	0	0	12	0	0	0	0	576
Hhm	60	25	973	17	2	74	21	1	12	2	10	0	12	1209
Cf	4	0	0	331	0	1	0	0	22	0	6	0	0	364
Ca	17	0	0	0	345	0	0	0	11	0	0	0	0	373
Ci	0	0	38	6	0	742	57	134	0	0	9	44	0	1030
Cv	2	0	34	0	0	44	715	41	0	0	46	0	0	882
Dd	0	0	3	0	0	118	71	467	0	0	4	0	0	663
Fs	2	28	0	21	0	1	0	1	681	0	0	0	18	752
Tuz	0	0	8	0	0	1	0	0	0	107	1	14	3	134
Sda	4	0	23	0	0	36	0	0	0	2	206	2	0	273
Dac	0	0	0	0	0	0	0	0	0	1	0	173	0	174
Vhu	4	7	2	0	0	0	0	0	8	0	0	0	93	114
Total	388	661	1119	405	352	1021	865	646	763	112	282	233	134	6981

Apéndice 2. Exactitud a nivel de productor y usuario según producto

Mapas – estadístico		Huv	Mn	Hbm	Cf	Ca	Ci	Cv	Dc	Fs	Tuz	Sda	Dac	Vhu
S1S2RF_uy	Exactitud Productor	0.76	0.82	0.91	0.89	0.99	0.82	0.83	0.67	0.88	0.99	0.68	0.95	0.69
	Exactitud Usuario	0.68	0.91	0.82	0.95	0.93	0.73	0.81	0.85	0.92	0.74	0.79	0.94	0.74
S1S2SVM_uy	Exactitud Productor	0.76	0.85	0.87	0.82	0.98	0.73	0.83	0.72	0.89	0.96	0.73	0.74	0.69
	Exactitud Usuario	0.68	0.98	0.8	0.91	0.92	0.72	0.81	0.7	0.91	0.8	0.75	0.93	0.82

