



CASO PRÁCTICO

Cartografía de los ambientes naturales y antrópicos de Entre Ríos (Argentina) utilizando clasificación de aprendizaje automático

Julián Alberto Sabattini^{1a}, Rafael Alberto Sabattini^{1b}, Norberto Muzzachiodi², Irina Treisse³, Rodrigo Penco⁴

¹ *Ecología de los Sistemas Agropecuarios, Facultad de Ciencias Agropecuarias, Universidad Nacional de Entre Ríos. CONICET. Ruta N°11 - 10,5 km, Oro Verde, Argentina.*

² *Facultad de Bioquímica y Ciencias Biológicas, Universidad Nacional del Litoral, Santa Fe, Argentina.*

³ *Instituto Nacional de Limnología (INALI-CONICET-UNL), Ciudad Universitaria, Santa Fe, Argentina.*

⁴ *Departamento Socioeconómico, Facultad de Ciencias Agropecuarias, Universidad Nacional de Entre Ríos, Ruta N°11 - 10,5 km, Oro Verde, Argentina.*

Resumen: Entre Ríos presenta un paisaje particular con numerosos ambientes contrastantes. Cartografiar tanto los naturales y como los antrópicos es una tarea frecuente gracias a la utilización de tecnologías de percepción remota junto con los sistemas de información geográfica. Conocer qué, cuánto y dónde se encuentran es indispensable para diseñar estrategias de uso sostenible y de conservación de recursos naturales en un territorio. La libre accesibilidad de los datos y la capacidad de procesamiento en la nube de toda esta información es determinante para procesar y clasificar la vegetación de un área determinada. El objetivo fue confeccionar un mapa actualizado y rápidamente actualizable en el futuro con el mismo método de los ambientes naturales y antrópicos más representativos de la provincia de Entre Ríos conociendo cuál es la mejor época del año en la cual se maximiza el porcentaje de acierto de clasificación de algoritmos automáticos de cada ambiente. Utilizar algoritmos automáticos de aprendizajes de clasificación fue útil para conocer la extensión de los ecosistemas naturales y antrópicos en un amplio territorio. Las herramientas de *Google Earth Engine* permitieron seleccionar la época del año en la cual se maximiza el porcentaje de acierto y disminuye la probabilidad de error con bajo costo computacional y operacional. Los resultados obtenidos son indispensables para planificar políticas públicas de forma precisa y certera para las actividades productivas, como así también para la conservación de los recursos naturales.

Palabras clave: dinámica cobertura del suelo, *Google Earth Engine*, Sentinel-2, clasificación supervisada.

Mapping of the natural and anthropic environments of Entre Rios (Argentina) using machine learning classification

Abstract: Entre Ríos presents a distinctive landscape with numerous contrasting environments. Mapping both natural and anthropic features is a common task facilitated using remote sensing technologies alongside geographic information systems. Knowing what, how much, and where they are located is essential for designing sustainable use and conservation strategies for natural resources in a territory. The free accessibility of data and the cloud processing capability for all this information are crucial for processing and classifying the vegetation of a specific area. The aim was to create an updated map that can be easily updated in the future, using the same

To cite this article: Sabattini, J.A., Sabattini, R.A., Muzzachiodi, N., Treisse, I., Penco, R. 2024. Mapping of the natural and anthropic environments of Entre Rios (Argentina) using machine learning classification. *Revista de Teledetección*, 64, 49-60. <https://doi.org/10.4995/raet.2024.20831>

* Corresponding author: julian.sabattini@uner.edu.ar

method for the most representative natural and anthropic environments in the province of Entre Ríos. This involves determining the best time of the year to maximize the accuracy percentage of automatic algorithm classification for each environment. Employing automatic classification learning algorithms was useful in understanding the extent of natural and anthropic ecosystems across a vast territory. Google Earth Engine tools allowed for selecting the optimal time of year to maximize accuracy percentage and minimize the probability of error with low computational and operational costs. The results obtained are indispensable for planning precise and accurate public policies for productive activities, as well as for the conservation of natural resources.

Key words: land cover dynamics, Google Earth Engine, Sentinel-2, supervised classification.

1. Introducción

Cartografiar los ecosistemas y agroecosistemas consiste en conocer cuál es la superficie ocupada de cada clase y cómo están distribuidos en el espacio en un momento dado (Coca-Castro *et al.*, 2021) siendo clave para implementar políticas de gestión y tomar decisiones sobre el territorio adecuadas, ya sea para el aprovechamiento sostenible como para la conservación (Crossman *et al.*, 2013).

La fotointerpretación es una técnica que contribuye a cartografiar las unidades fisonómicas de cada ecosistema o agroecosistema (Seidlova *et al.*, 2021) por sus atributos como, por ejemplo: estructura, fisonomía y composición florística. Un caso local son los bosques nativos del espinal entrerriano (Sabattini *et al.*, 2010). Los sensores remotos automatizan el proceso junto con las técnicas de procesamiento digital de imágenes integradas a los Sistemas de Información Geográfica (Pérez-Cutillas *et al.*, 2023). Estos facilitan rápidamente la adquisición y el procesamiento de información básica permitiendo obtener mapas que ubican a los diferentes ecosistemas y agroecosistemas mediante diversos métodos de clasificación (Congalton y Green, 2019). Coberturas de suelo y tipos de vegetación diferentes son claves al momento de clasificar imágenes satelitales en ambientes contrastantes (Paruelo *et al.*, 2014).

La disponibilidad de información sobre sensores remotos de acceso abierto y libre aumentó en la última década exponencialmente (Lin *et al.*, 2018). (GEE) ofrece un catálogo amplio de imágenes satelitales y diferentes modelos de aprendizaje automático para clasificación (Gorelick *et al.*, 2017, Tamiminia *et al.*, 2020). Esta herramienta ha sido mundialmente utilizada para el monitoreo de la deforestación (Chen *et al.*, 2021), de sequías (Zaho *et al.*, 2021) e incendios forestales (Sharma

et al., 2022), y la clasificación de la cobertura del suelo (Stromann *et al.*, 2020), entre otras aplicaciones. Localmente ha sido útil para cartografiar la vegetación (Paruelo *et al.*, 2014), reportando posibles inconvenientes en situaciones particulares como son los bosques nativos (Sabattini *et al.*, 2010).

Entre Ríos es una provincia particular de la República Argentina debido a su paisaje ondulado resultando una variedad de ambientes heterogéneos. Desde inicios del siglo xx se reportan mapas de la vegetación, pero hasta finales de siglo, los intentos de cartografiar han sido parciales y enfocados solo en los ambientes más degradados sin abarcar la totalidad del territorio (Jozami y Muñoz, 1982; Muñoz *et al.*, 2005; Sabattini *et al.*, 2015; Avogadro y Padró-García, 2019). Las diferencias metodológicas hacen dificultoso su análisis y por tanto son punto controversial de discusión por la ausencia de datos confiables, precisos y actuales sobre la cantidad, localización y estado de los recursos naturales y antrópicos.

Por tal motivo, cartografiar la distribución actualizada de los ecosistemas y agroecosistemas de la provincia de Entre Ríos es un producto necesario. Hasta el momento no existe un mapa completo de los ambientes más representativo de Entre Ríos basado en combinar el relevamiento de campo con procesamiento de imágenes satelitales de mediana resolución. En consecuencia, los objetivos de este trabajo son: 1) conocer cuál es la mejor época del año que maximiza el porcentaje de acierto de clasificación de algoritmos automáticos de cada ambiente, y 2) confeccionar un mapa actualizado de los ambientes naturales y antrópicos más representativos de la provincia de Entre Ríos.

2. Materiales y Métodos

2.1. Área de estudio

La provincia de Entre Ríos se encuentra entre la latitud sur $30^{\circ} 10'$ a $34^{\circ} 03'$, y los $57^{\circ} 48'$ y $60^{\circ} 47'$ de longitud oeste. Cuenta con 78781 km², de las cuales 66976 km² son considerados de tierra firme, mientras que 11805 km² son islas y tierras anegadizas (menor a 20 m s.n.m.). Geográficamente tiene lomadas en el Centro-Norte y tierras planas hacia el Sur. Estas elevaciones y depresiones generan numerosos cursos de agua permanentes y temporarios (Plan Mapa de Suelos, 1980). Al Norte el clima es subtropical húmedo de llanura, mientras en el Centro y Sur del territorio, templado húmedo. La temperatura media anual es de 18,9 °C, con una precipitación media anual que aumenta de sur a norte entre 900 a 1100 mm concentradas entre los meses de octubre y marzo (Osztust *et al.*, 2019). La vegetación nativa está representada por tres biomas destacables: el pastizal natural, el bosque nativo, y los ambientes inundables deltaicos (Oyarzabal *et al.*, 2018).

Para ejecutar algoritmos de clasificación, inicialmente se delimitó el área de interés. El punto de partida para separar unidades ambientales fue el relieve particular y su consecuencia en los factores bióticos y abióticos. Lomadas importantes, como así también depresiones con concavidades de consideración que generan la red de ríos y arroyos, crean una condición particular de los ambientes

inundables dependientes de la acción fluviomorfológica. Por ello, se reafirmó la teoría propuesta por Sabattini *et al.* (1999) en separar dos grandes situaciones según la cota topográfica 20 m. s.n.m. Cuando es superior lo denominamos ‘ambientes de tierra firme’, pero cuando es menor corresponden a ‘ambientes inundables’. Estos últimos son altamente heterogéneos y están determinados por las diferentes zonaciones de las islas o bañados con dominancia de los pajonales, carrizales y canutillares, pero también con el desarrollo de una selva en galería marginal sobre los albardones (Oyarzabal *et al.*, 2018). Para esta primera separación, se utilizaron modelos digitales de terrenos obteniendo un vector de delimitación del área de interés donde se ejecutaron todos los algoritmos de clasificación. Posteriormente, nueve categorías de clasificación de los ambientes naturales y antrópicos fueron establecidas y descritas basadas en la fisonomía vegetal, en la estructura de sus estratos que la componen, y en la composición florística dominante de cada uno (Figura 1, Tabla 1 Material Suplementario).

2.2. Selección de imágenes satelitales

Desde la plataforma (GEE) se accedió a las colecciones de imágenes Sentinel-2 de sus servidores a través de una API basada en JavaScript/Python (GEE API) (Goldblatt *et al.*, 2017). Sentinel-2 es una misión de la Agencia Espacial Europea (ESA) y está compuesta por satélites que llevan



Figura 1. Imágenes fotográficas de las categorías de los ambientes naturales y antrópicos utilizados para la clasificación propuesta.

sensores ópticos multiespectrales. Se utilizaron productos Sentinel-2A con nivel de procesamiento BOA-S2_SR, es decir, con cálculo de reflectancia en el techo de la atmósfera y en superficie, recomendado para este tipo de estudios (Astola et al., 2021). El sensor óptico MSI incluye 13 bandas espectrales con una resolución espacial máxima de 10 m (ESA, 2020). Estas imágenes fueron seleccionadas en otros trabajos de similares características (Mahdianpari et al., 2020; Singha et al., 2020; Stromann et al., 2020). En este estudio, se utilizaron las bandas azul, verde, rojo e infrarrojo cercano a 10 m de resolución espacial (Liu et al., 2021). Para cada estación astronómica, se calculó una nueva imagen basada en la mediana de todas las imágenes disponibles de 2020 al 2021 en GEE con un porcentaje de nubes inferior al 20%. Para otoño de 2020 se consideró el período del 21 de marzo al 20 de junio; para invierno del 21 de junio al 20 de septiembre; para primavera del 21 de septiembre al 20 de diciembre; y para verano del 21 de diciembre de 2020 al 20 de marzo de 2021. Esto fue posible a partir de operaciones matemáticas `ee.Reducer.median()` permitidas en la API de GEE. La elección de la mediana se sustenta en su capacidad de resumir información de todas las imágenes disponibles en cada período (Ghorbanian et al., 2020; Naboureh et al., 2020). Disponer de una clasificación por estación se sustenta en la dinámica temporal de la cobertura de los cultivos agrícolas, como también, en la fenología intrínseca de los componentes arbóreos, arbustivos y herbáceos.

2.3. Selección del método de clasificación y validación

Se aplicaron algoritmos de aprendizaje automático supervisados a través del catálogo de imágenes de la plataforma GEE (Jinxia et al., 2022). Si bien existe cierta resistencia al uso de los mismos en aplicaciones ecológicas porque la disciplina ha aplicado la estadística paramétrica tradicional durante décadas (Evans et al., 2011), recientemente se ha popularizado y utilizado el aprendizaje automático supervisado (Hansen et al., 2013; Hethcoat et al., 2019). GEE ofrece un conjunto de algoritmos clasificadores (CART, NaiveBayes y SVM), y entre ellos se encuentra *Random Forest* (Magidi et al., 2021). Es una técnica de entrenamiento supervisado y no paramétrico que realiza

varios árboles de decisión y calcula la respuesta en función del resultado de todos los árboles, dando lugar a clasificaciones altamente precisas (Rodríguez-Galiano et al., 2012). Además, tiene mayor tolerancia al ruido evitando posibilidades de sobreajuste (Belgiu y Dragut 2016; Morell-Monzó et al., 2021), lo cual permite una mejora en la capacidad para manejar datos de alta dimensión produciendo mapas prometedores (Ghorbanian et al., 2020). Esta técnica es usada frecuentemente en estudios con bosques (Li et al., 2017; Montaña et al., 2017; Ghorbanian et al., 2021), pastizales (Zhao et al., 2022), y cultivos (Suryono et al., 2022), entre otros.

Para asignar las áreas de entrenamiento y validación del algoritmo, inicialmente se realizó un relevamiento de campo previo para conocer y vincular las estructuras de las nueve categorías con los patrones de las imágenes satelitales. Durante el año 2020 y 2023 se realizaron 2 530 km por rutas nacionales y provinciales, como también por caminos de tierra abarcando la mayor parte del territorio provincial (Figura 2). De forma aleatoria se realizaron muestreos posicionados con GPS, registrando la información sobre la categoría. Al mismo tiempo, a los efectos de ampliar el rango de visión y acceder a lugares más difíciles, se utilizó

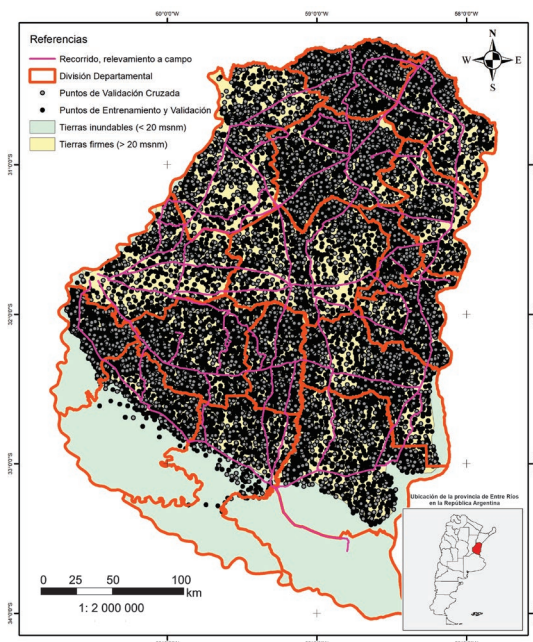


Figura 2. Ubicación del recorrido a campo realizado, y los sitios de entrenamiento y validación de las clasificaciones.

un vuelo en primera persona con un dron, registrando fotos y videos de los diferentes ambientes, tal como se plantean en estudios similares para otras regiones del mundo (Zhao *et al.*, 2022).

A partir de estos relevamientos de campo, como también del conocimiento previo del territorio de otros estudios realizados (Sabattini *et al.*, 2015; Sabattini *et al.*, 2019), se vectorizaron manualmente puntos en forma aleatoria sobre imágenes de alta resolución espacial disponibles asignándole a cada uno de ellos una de las nueve categorías. Las características espectrales, texturales y espaciales fueron necesarias para clasificar manualmente mediante fotointerpretación cada punto (Shetty *et al.*, 2021), sumado a la extensa experiencia y datos de campo colectados del territorio. Otros estudios mencionan que la precisión de la interpretación visual es alta, con limitaciones por el alto costo operacional, cuando son extensas áreas y múltiples tipos de categorías. Sin embargo, es una información indispensable para el correcto aprendizaje automático (Fang *et al.*, 2021).

Se ubicaron 13284 puntos distribuidos en todos los departamentos de la provincia de Entre Ríos, de los cuales el 70% de ellos fueron seleccionados aleatoriamente y utilizados para realizar el entrenamiento y validación del algoritmo de clasificación (Figura 1). Con el porcentaje de puntos restantes (30%) se realizó una segunda validación comparando los valores observados con los obtenidos por la clasificación. Luego se elaboró una matriz de confusión, conocida como matriz de error, siendo un formato estándar para representar la evaluación de la precisión de la clasificación (Townsend, 1971). A partir de ella se calculó la precisión general (PG) y el coeficiente kappa (K), indicadores que reflejan la calidad de la clasificación de imágenes satelitales desde diferentes aspectos. Posteriormente, entre la estación de otoño y verano se aplicó una prueba para evaluar sus diferencias. Individualmente, en cada clase se estimaron cuatro parámetros para todos los departamentos de Entre Ríos: a) exactitud del usuario (EU) que representa la probabilidad de que un píxel escogido aleatoriamente y clasificado en una unidad cartográfica del mapa esté correctamente asignado; b) riesgo del productor (RP) o error de comisión, es decir verdad terreno incluida erróneamente en una misma unidad cartográfica; c) exactitud del productor (EP) que

representa la probabilidad de que un píxel escogido aleatoriamente y perteneciente a una clase esté correctamente asignado a una unidad cartográfica; y d) riesgo del usuario (RU) correspondiente al porcentaje de elementos mal clasificados y, por tanto, corresponde un riesgo su utilización (Congalton y Green, 2019).

3. Resultados

3.1. Época del año vs. porcentaje de acierto de clasificación

Los índices de la calidad de clasificación fueron diferentes entre las épocas del año (Tabla 2) debido a la característica intrínseca de cada ambiente natural y antrópico que responde a una dinámica anual particular. Sin embargo, el porcentaje de acierto de la clasificación promedio de los departamentos fue superior al 80%, siendo un resultado aceptable. El área que representó cada punto de entrenamiento fue de 459 ha considerando toda la provincia, proporción que se mantuvo en casi todos los departamentos (Tabla 2, Material Suplementario). Sin embargo, en aquellos departamentos donde los ambientes naturales presentaban mayor ocupación de territorio, y podría existir mayor complejidad en la clasificación debido a similitudes espectrales, se amplió la cantidad de puntos por debajo de 300 hectáreas por punto (ejemplo Federal y Feliciano), o bien, en donde la superficie de tierra firme de los departamentos era más pequeña en relación con el resto como, por ejemplo, en Diamante y Victoria. En la estación de otoño se observó un mayor porcentaje promedio de acierto (84,1%) respecto al resto del año, obteniendo una clasificación aceptable según el índice kappa promedio (0,78). En particular se observó una diferencia estadística entre el otoño y el verano tanto para el porcentaje de acierto ($=41,23$, $p=0,0154$) como para el índice kappa ($=29,77$, $p=0,0214$). Desde el punto de vista práctico, estos resultados reflejan el contraste espectral esperado en función la fenología de los ambientes naturales y antrópicos que se desarrollan en gran parte del territorio provincial. En esta época del año, los cultivos agrícolas de verano se encuentran en su etapa de senescencia tanto para soja y maíz, mientras que para el sorgo presenta un contraste particular por su coloración rojiza debido a su estado de

Tabla 2. Índices de calidad de clasificación por estación del año para cada clasificación en los departamentos de Entre Ríos (PG: Precisión Global, K: Índice Kappa). Nota: el departamento Islas de Ibicuy quedo excluido de la clasificación dado que se encuentra por debajo de los 20 m. s.n.m. de cota.

Departamentos	Otoño		Invierno		Primavera		Verano	
	PG	K	PG	K	PG	K	PG	K
Colon	84,7%	0,80	84,7%	0,78	83,4%	0,79	84,7%	0,80
Concordia	87,1%	0,83	88,7%	0,86	88,7%	0,86	86,0%	0,82
Diamante	87,4%	0,81	87,9%	0,82	86,5%	0,80	86,6%	0,81
Federación	85,1%	0,82	79,5%	0,75	80,0%	0,75	77,3%	0,72
Federal	84,9%	0,79	83,5%	0,77	80,8%	0,73	81,7%	0,75
Feliciano	85,1%	0,82	82,1%	0,77	82,7%	0,78	80,7%	0,75
Gualedguay	82,8%	0,74	81,2%	0,72	80,3%	0,71	80,1%	0,69
Gualedguaychú	84,4%	0,75	86,1%	0,77	85,1%	0,77	81,2%	0,71
La Paz	68,7%	0,59	69,7%	0,60	66,5%	0,56	64,4%	0,53
Nogoyá	82,7%	0,76	83,7%	0,77	84,6%	0,78	77,4%	0,68
Paraná	88,5%	0,84	88,1%	0,83	89,8%	0,86	82,6%	0,76
San Salvador	86,9%	0,77	85,7%	0,74	85,5%	0,75	82,3%	0,67
Tala	77,6%	0,71	74,9%	0,67	76,4%	0,69	71,0%	0,61
Uruguay	88,1%	0,82	87,2%	0,80	86,8%	0,80	83,9%	0,75
Victoria	85,7%	0,80	84,6%	0,78	85,7%	0,80	82,9%	0,76
Villaguay	86,1%	0,82	85,7%	0,81	83,6%	0,79	82,9%	0,78
Promedio	84,1%	0,78	83,3%	0,77	82,9%	0,76	80,3%	0,72

madurez de la panoja. Por ello, el riesgo de que la categoría cultivos sea confundida es muy poco probable (8,3%) en virtud de lo obtenido en esa estación (Tabla 3). Al mismo tiempo, se comienzan a implantar praderas y verdeos de invierno, con lo cual el suelo desnudo es más relevante respecto a la biomasa generada por su escasa tasa de crecimiento inicial.

En este sentido, los ambientes antrópicos presentaron un contraste pronunciado respecto a la vegetación nativa (Tabla 3), en la cual tienen una coloración particular tanto para pastizales

naturales como para las coberturas de bosques nativos. En ambos casos, se observa visualmente una coloración y textura específica como consecuencia de un aumento en la biomasa característico de la curva de crecimiento para esta época del año. Una proporción de especies vegetales que conforman el estrato arbóreo, que en general son dominantes, comienza a perder parcialmente su follaje. Esta situación, sumado a una cobertura elevada de arbustivas, genera un contraste perfecto entre los bosques nativos cerrados y abiertos en virtud de la elevada producción primaria neta de las arbustivas en comparación

Tabla 3. Índices de calidad de clasificación por categorías para la estación de otoño y verano considerando el promedio de todos los departamentos de Entre Ríos.

Categorías de Clasificación	Estación de otoño				Estación de verano			
	EU	RP	EP	RU	EU	RP	EP	RU
Cuerpos de agua	87,0%	13,0%	94,2%	5,8%	92,4%	7,6%	92,8%	7,2%
Cultivos extensivos	91,7%	8,3%	87,3%	12,7%	87,1%	12,9%	80,4%	19,6%
Bosque nativo abierto	79,1%	20,9%	75,8%	24,2%	73,3%	26,7%	71,2%	28,8%
Bosque nativo cerrado	86,3%	13,7%	85,4%	14,6%	81,9%	18,1%	84,2%	15,8%
Usos de suelo (canteras)	86,0%	14,0%	84,1%	15,9%	86,0%	14,0%	94,9%	5,1%
Zonas urbanas y ejidos adyacentes	73,2%	26,8%	89,9%	10,1%	66,0%	34,0%	82,1%	17,9%
Pastizal natural de tierra firme	73,1%	26,9%	77,8%	22,2%	72,1%	27,9%	76,2%	23,8%
Pastizal natural con vegetación higrófila	59,2%	40,8%	79,1%	20,9%	54,9%	45,1%	77,0%	23,0%
Plantaciones forestales y cítricas	90,3%	9,7%	96,1%	3,9%	84,0%	16,0%	94,6%	5,4%

con el estrato herbáceo inferior. Durante el otoño ambas categorías fueron bien clasificadas, 86,3% y 79,1%, respectivamente (Tabla 3). El bosque nativo abierto presentó mayor confusión de clasificación con el pastizal natural de tierra firme (Tabla 3 Material Suplementario) pero la probabilidad de error fue menor al 25%. Sin embargo, el bosque nativo cerrado presentó una probabilidad de error menor al 15% en la estación de otoño, comparada a la respuesta en el verano. Esta respuesta continúa hasta el invierno, pero el porcentaje de acierto general se reduce (83%) por las bajas temperaturas que afectan a la vegetación nativa en su tasa de crecimiento matizando los contrastes generados, y también, porque los cultivos de invierno con destino agrícola y ganadero expresan su crecimiento.

La primavera presentó aún menores contrastes debido a los picos de crecimiento de la vegetación nativa ya sea del estrato arbóreo, arbustivo y herbáceo, como también de praderas implantadas. Además, se le suma la finalización del ciclo de los cultivos de invierno y la siembra de cultivos de verano como por ejemplo de girasol, maíz, sorgo y soja. Cuando estos últimos maximizan su producción de biomasa, es decir, en la estación de verano fue más dificultoso obtener diferencias entre los ambientes naturales y

antrópicos evidenciado por un aumento en errores probabilísticos para cada clase. Por tanto, en este estudio se obtuvo que el otoño es la estación del año en la cual se espera mayor contraste entre los tres ambientes más representativos de la provincia de Entre Ríos. Las plantaciones forestales, las zonas urbanas y los usos de suelos con fines civiles presentan menor variabilidad durante el año, y el porcentaje de error en la clasificación fue del 10,1% (Tabla 3).

Cuando se realizó la validación posterior a la clasificación, los porcentajes de acierto en general descendieron (Tabla 4), obteniendo un promedio del 64,3% en el otoño, acentuando la diferencia con la estación de verano (56,3%).

3.2. Mapa de los ambientes naturales y antrópicos de Entre Ríos

En la Figura 3 se presenta la ocupación de los ambientes naturales y antrópicos de la provincia de Entre Ríos obtenida para la estación de otoño 2020, que presentó el mejor índice de acierto de la clasificación realizada. Los resultados indican que el 60,4% del territorio corresponden a ambientes naturales conformado por bosques nativos (26,4%, 2 065 774 ha), pastizal natural con vegetación higrófila (22,2%, 1 737 504 ha)

Tabla 4. Índices de calidad de clasificación basados en puntos de validación por estación del año para departamentos de Entre Ríos (PG: Precisión Global, K: Índice Kappa). Nota: el departamento Islas de Ibicuy quedó excluido de la clasificación dado que se encuentra por debajo de los 20 m .s.n.m. de cota.

Departamentos	Otoño		Invierno		Primavera		Verano	
	PG	K	PG	K	PG	K	PG	K
Colon	61,6%	0,52	65,2%	0,57	62,2%	0,52	52,4%	0,40
Concordia	65,4%	0,57	67,3%	0,59	65,4%	0,57	64,7%	0,55
Diamante	72,0%	0,57	72,0%	0,57	71,0%	0,57	63,0%	0,42
Federación	59,6%	0,50	55,3%	0,45	52,8%	0,42	50,6%	0,39
Federal	59,8%	0,47	60,8%	0,48	57,7%	0,44	53,8%	0,39
Feliciano	60,5%	0,48	60,8%	0,49	56,7%	0,44	49,5%	0,34
Gualaguay	62,0%	0,38	55,0%	0,26	59,0%	0,34	48,0%	0,13
Gualaguaychú	64,0%	0,42	66,0%	0,45	70,0%	0,55	58,0%	0,33
La Paz	56,9%	0,44	58,3%	0,45	58,1%	0,44	55,4%	0,41
Nogoyá	67,4%	0,53	66,1%	0,52	65,8%	0,51	59,7%	0,43
Paraná	74,2%	0,64	75,7%	0,66	79,1%	0,71	63,8%	0,49
San Salvador	55,8%	0,34	57,1%	0,32	55,1%	0,34	52,4%	0,23
Tala	65,5%	0,54	60,5%	0,48	56,1%	0,41	51,8%	0,35
Uruguay	71,4%	0,54	77,3%	0,63	75,4%	0,59	66,9%	0,43
Victoria	68,0%	0,54	66,0%	0,51	67,0%	0,53	53,0%	0,32
Villaguay	65,5%	0,51	60,1%	0,48	66,2%	0,55	57,8%	0,45
Promedio	64,3%	0,50	64,0%	0,49	63,6%	0,50	56,3%	0,38

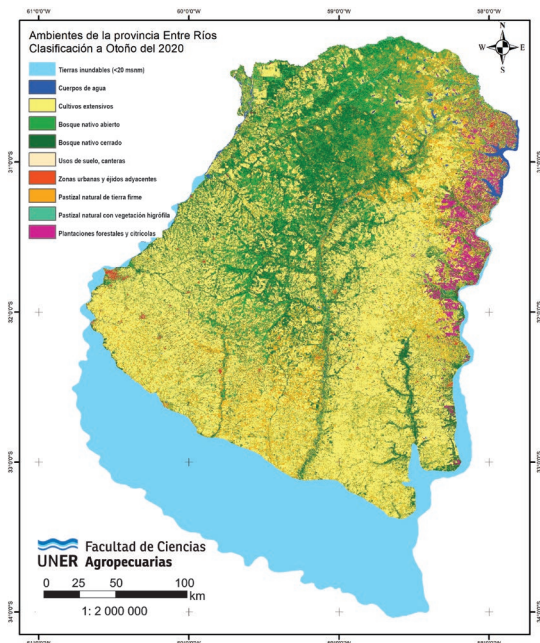


Figura 3. Mapa de ocupación de los ambientes naturales y antrópicos para otoño 2020 en la provincia de Entre Ríos (Argentina).

y de tierra firme (11,9%, 930 332 ha); mientras que el porcentaje restante a sistemas antropizados con cultivos extensivos e intensivos (38,1%, 2 980 302 ha) y usos de la tierra para el desarrollo humano (1,5%, 118 417 ha).

Considerando los ambientes naturales, el pastizal natural fue el bioma dominante territorialmente con más de 2 667 837 ha, destacándose la región deltaica del Río Paraná al sur de la provincia (Figura 2). En cambio, los bosques nativos se ubicaron en el sector centro norte totalizando el 78% de la superficie total en departamentos La Paz, Federal, Feliciano, Villaguay, Paraná, Nogoya, Tala. El porcentaje restante se distribuyen sobre la margen de los ríos y arroyos más importantes de la región centro Sur, y Este de la provincia. Por otro lado, se observó una proporción similar entre bosques nativos abiertos y cerrados, siendo levemente mayor en los primeros (53% y 47%, respectivamente). Las áreas de cultivos extensivos se ubicaron en el centro Sur y Este del territorio provincial, pero también de forma fragmentada en toda la región norte compartiendo con ecosistemas boscosos (Figura 3).

4. Discusión

La utilización de algoritmos de clasificación automática con supervisión para conocer dónde y cuál es la superficie ocupada por cada ambiente resultó una técnica de implementación rápida y de bajo costo, tal como reportan otros estudios (Liu *et al.*, 2021; Hethcoat *et al.*, 2019; Pérez-Cutillas *et al.*, 2023). La disponibilidad gratuita y capacidad de implementar los algoritmos dentro de la plataforma GEE permitió realizar este estudio en tiempos reducidos y con bajo costo computacional, característica destacada por numerosos estudios en la región y en el mundo (Naboureh *et al.*, 2020; Ghorbanian *et al.*, 2021; Liu *et al.*, 2021; Magidi *et al.*, 2021; Luo *et al.*, 2022). Sin embargo, es indispensable contar con un relevamiento de campo exhaustivo para vincular el valor observado en terreno con la resultante clasificación obtenida. La disponibilidad de imágenes satelitales con alta resolución espacial es una ventaja destacable cuando se diseña un sistema automático de monitoreo basado en el aprendizaje previo (Stromann *et al.*, 2020; Shetty *et al.*, 2021) sustentado en una base de información robusta como la utilizada en este manuscrito.

En virtud de esto, este trabajo ofrece una mejoría respecto a otros estudios sin GEE para la región dado que los ambientes naturales y antrópicos presentes tienen en diversos momentos del año similitudes espectrales (Sabattini *et al.*, 2010; Sabattini *et al.*, 2015; Avogadro y Padró-García, 2019) que dificultan el nivel de separación de las clases (Johansen y Phinn, 2006). Por tal motivo la ‘fenología’ del ambiente durante el año resulta ser un factor determinante. Los pastizales naturales y los bosques nativos en épocas primaverales y estivales con plenitud del período vegetativo y reproductivo (Sharma *et al.*, 2022; Zhao *et al.*, 2022; Grabska-Szwagrzyk y Tymińska-Czabańska, 2023) resultarían ser desventajosos para su discriminación, situación que es coincidente con el desarrollo de los cultivos extensivos de cereales y oleaginosas típicos, como maíz, sorgo y soja en donde aumentan su índice de vegetación (Tran *et al.*, 2022). Si bien estos tienen mayor homogeneidad espacial, no evitan las confusiones cuando se las quiere clasificar. Sin embargo, durante el otoño se produce otro pico de incremento de biomasa en ecosistemas naturales que coincide con el final del ciclo ontogénico de los cultivos extensivos. Esto conlleva a un mejor nivel de acierto por los algoritmos de clasificación automática.

Los cultivos extensivos junto con las plantaciones forestales tienen patrones espaciales regulares debido, por un lado, a la regularidad de las parcelas, y por otro, a la fisonomía vertical de estos cultivos generando una dominancia en competencia ecológica a nivel de comunidad vegetal (Viña *et al.*, 2016). En cambio, ecosistemas con fisonomías y estructuras de la vegetación similares (pastizal natural y bosque nativo) ocasionan una disminución en la probabilidad de acierto de las clasificaciones.

Otro aspecto a tener en cuenta es la composición florística de los ecosistemas. En el bosque nativo, el índice de área foliar desciende durante el otoño como consecuencia de la latencia invernal del género *Prosopis* spp. (Zerda y Tiedemann, 2010; Burry *et al.*, 2018), dominante en su composición florística (Sabattini *et al.*, 2008). En cambio, las especies exóticas implantadas permanecen con follaje vigoroso. La similitud espectral puede ser más notable desde finales de primavera hasta mediados del verano, en la cual ambas unidades ambientales están en su ciclo ontogénico de mayor vigor vegetativo.

En términos cuantitativos, fue posible conocer la superficie de ambientes naturales y antrópicos que tiene la provincia de Entre Ríos, en particular de ecosistemas altamente fragmentados por el avance del cambio de uso y cobertura de la tierra ocasionado en las últimas dos décadas: el bosque nativo. Si bien, representan el 26,4% del territorio provincial (más de 2 millones de ha), los pastizales naturales es el ecosistema natural más representativo del territorio superando el 34,1% de la superficie provincial. Esto indica que la provincia cuenta con un 60% del territorio cubierto por ecosistemas naturales muy valiosos para la producción agropecuaria sostenible, como también para implementar un plan de conservación de mediano y largo plazo, formando parte de un activo ambiental importante. Estos ecosistemas contribuyen a mitigar efectos negativos del cambio climático global (Nascimento y Campos, 2011).

La ausencia de información confiable y actualizada ha generado incertidumbre sobre la degradación forestal (Sabattini *et al.*, 1999). Los inventarios parciales y/o deficientes llevó a desconocer cuál es punto de partida histórico sobre la cubierta boscosa provincial, situación reportada en las últimas décadas (Sabattini *et al.*, 2015). Entre Ríos en el año 2014 sancionó la Ley 10284, en la cual reportaron 1,8 millones de hectáreas de bosques sin informar la metodología utilizada, ni las validaciones que

respaldan dicha información. En este sentido, los métodos utilizados en este trabajo resultarían más robustos y pueden ser considerados para un ordenamiento territorial integral.

5. Conclusión

Utilizar algoritmos automáticos de aprendizajes de clasificación satelital fue útil para conocer la extensión de los ecosistemas naturales y antrópicos en un extenso territorio. La fenología y los ciclos ontogénicos de las comunidades vegetales generan confusiones en la clasificación. Las herramientas de GEE han permitido seleccionar la época del año en la cual se maximiza el porcentaje de acierto y disminuye la probabilidad de error con bajo costo computacional y operacional. Los resultados obtenidos son indispensables para planificar políticas públicas de forma precisa y certera para las actividades productivas y la conservación de los recursos naturales. El último reporte disponible tiene una década de antigüedad, y este trabajo no solo actualiza las cifras, sino que propone lineamientos y herramientas probadas para aplicar en el futuro.

Agradecimientos

Los autores agradecen a los revisores anónimos que aportaron visión crítica al manuscrito. Este trabajo se realizó en marco al Proyecto de Investigación PID UNER N°2238 denominado “Evaluación del estado actual y potencial de los bosques nativos de Entre Ríos en su aspecto productivo y de conservación”.

Material suplementario

El material suplementario se encuentra disponible en: <https://doi.org/10.4995/raet.2024.20831>.

Referencias

- Ariza, A. 2006. Análisis del retroceso de glaciales tropicales en los Andes Centrales de Colombia mediante imágenes Landsat. *Revista Cartográfica*, (82), 57.
- Astola, H., Seitsonen, L., Halme, E., Molinier, M., Lönnqvist, A. 2021. Deep Neural Networks with Transfer Learning for Forest Variable Estimation Using Sentinel-2 Imagery in Boreal Forest. *Remote Sens.*, 13, 2392. <https://doi.org/10.3390/rs13122392>

- Avogadro, E.G., Padró, J.C. 2019. Diferenciación de plantaciones forestales en Entre Ríos (Argentina): comparación de métodos de clasificación aplicados a imágenes Sentinel-2 y Landsat-8. *GeoFocus*, 24, 117-139. <https://doi.org/10.21138/GF.652>
- Belgiu M., Dragut L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Burru L.S., Palacio P.I., Somoza M., Trivi de Mandri M.E., Lindskoug H.B., Marconetto M.B., D'Antoni H. 2018. Dynamics of fire, precipitation, vegetation and NDVI in dry forest environments in NW Argentina. Contributions to environmental archaeology. *Journal of Archaeological Science: Reports*. 18, 747-757. <https://doi.org/10.1016/j.jasrep.2017.05.019>.
- Chen, S., Woodcock, C.E., Bullock, E.L., Arévalo, P., Torchinava, P., Peng, S., Olofsson, P. 2021. Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. *Rem. Sens. Environ.*, 265, 112648. <https://doi.org/10.1016/j.rse.2021.112648>.
- Coca-Castro, A., Zaraza-Aguilera, M.A., Benavides-Miranda, Y.T., Montilla-Montilla, Y.M., Posada-Fandiño, H.B., Avendaño-Gomez, A.L., Hernández-Hamon, H.A., Garzón-Martínez, S.C., Franco-Prieto, C.A. 2021. Evaluación de algoritmos de clasificación en la plataforma Google Earth Engine para la identificación y detección de cambios de construcciones rurales y periurbanas a partir de imágenes de alta resolución. *Revista de Teledetección*, (58), 71-88. <https://doi.org/10.4995/raet.2021.15026>
- Congalton, R.G., Green, K. 2019. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Third Edition (3rd ed.). CRC Press. <https://doi.org/10.1201/9780429052729>
- Crossman, N.D., Burkhard, B., Nedkov, S., Willemsen, L., Petz, K., Palomo, I., Drakou, E.G., Martín-López, B., McPhearson, T., Boyanova, K., Alkemade, R., Egoh, B., Dunbar, M.B., Maes, J. 2013. A blueprint for mapping and modelling ecosystem services. *Ecosystem services*, 4, 4-14. <https://doi.org/10.1016/j.ecoser.2013.02.001>
- Dozier J. 1989. Spectral signature of alpine snow cover from the landsat thematic mapper. *Remote Sens. Environ.*, 28, 9-22. [https://doi.org/10.1016/0034-4257\(89\)90101-6](https://doi.org/10.1016/0034-4257(89)90101-6).
- ESA, User Guides–Sentinel-2 MSI–Sentinel Online [WWW Document], URL <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/processing-levels> (accessed 3.16.20)
- Evans, J.S., Murphy, M.A., Holden, Z.A., Cushman, S.A. 2011. Modeling species distribution and change using random forest. In: Drew C.A., Wiersma Y.F., Huettmann F., eds. *Predictive species and habitat modeling in landscape ecology: concepts and applications*. New York City, NY, USA: Springer Science+Business Media. pp. 139–159. https://doi.org/10.1007/978-1-4419-7390-0_8
- Fang H., Jamali B., Deletic A., Zhang K. 2021. Machine learning approaches for predicting the performance of stormwater biofilters in heavy metal removal and risk mitigation. *Water Research*, 200: 117273. <https://doi.org/10.1016/j.watres.2021.117273>.
- Ghorbanian, A., Kakooei, M., Amani, M., Mahdavi, S., Mohammadzadeh, A., Hasanlou, M. 2020. Improved land cover map of Iran using Sentinel imagery within Google Earth Engine and a novel automatic workflow for land cover classification using migrated training samples. *ISPRS J. Photogramm. Remote Sens.*, 167, 276-288. <https://doi.org/10.1016/j.isprsjprs.2020.07.013>
- Ghorbanian, A.; Zaghian, S.; Asiyabi, R.M.; Amani, M.; Mohammadzadeh, A.; Jamali, Mangrove S. 2021. Mangrove Ecosystem Mapping Using Sentinel-1 and Sentinel-2 Satellite Images and Random Forest Algorithm in Google Earth Engine. *Remote Sens.*, 13, 2565. <https://doi.org/10.3390/rs13132565>
- Goldblatt, R., Rivera Ballesteros, A., Burney, J. 2017. HighSpatial Resolution Visual Band Imagery Outperforms MediumResolution Spectral Imagery for Ecosystem Assessment in the Semi-Arid Brazilian Sertão. *Remote Sens.*, 9, 1336. <https://doi.org/10.3390/rs9121336>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R. 2017. Google earth engine: planetary-scale geospatial analysis for everyone. *Rem. Sens. Environ.*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Grabska-Szwagrzyk, E., Tymińska-Czabańska, L. 2023. Sentinel-2 time series: a promising tool in monitoring temperate species spring phenology, *Forestry: An International Journal of Forest Research*. cpad039, <https://doi.org/10.1093/forestry/cpad039>
- Hansen M.C., Potapov P.V., Moore R., Hancher M., Turbanova S.A., Tyukavina A., Thau D., Stehman S., Goetz S.J., Loveland T.R., Kommareddy A., Egorov A., Chini L., Justice C.O., Townshend J.R.G. 2013. High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342, 6160.
- Hethcoat M.G., Edwards D.P., Carreiras J.M.B., Bryant R.G., França F.M., Quegan S. 2019. A machine learning approach to map tropical selective logging. *Remote Sens. Environ.*, 221, 569-582. <https://doi.org/10.1016/j.rse.2018.11.044>.

- Jinxia, Y., Wu, J., Xiao, C., Zhang, Z., Li, J. 2022. The classification method study of crops remote sensing with deep learning, machine learning, and google earth engine. *Rem. Sens.*, 14(12), 2758. <https://doi.org/10.3390/rs14122758>.
- Johansen K., Phinn S. 2006. Mapping Structural Parameters and Species Composition of Riparian Vegetation Using IKONOS and Landsat ETM Data in Australian Tropical Savannahs. *Photogrammetric Engineering & Remote Sensing*. 72(1), 71-80. <https://doi.org/10.14358/PERS.72.1.71>
- Jozami J.M., Muñoz J.D. 1982. *Árboles y arbustos indígenas de la Prov. de Entre Ríos*. IPNAYS CONICET-UNL. Santa Fe, 407 pp.
- Li, A., Dhakal, S., Glenn, N.F., Spaete, L.P., Shinneman, D.J., Pilliod, D.S., Arkle, R.S., McIlroy, S.K. 2017. Lidar Aboveground vegetation biomass estimates in Shrublands: prediction, uncertainties and application to coarser scales. *Remote Sensing.*, 9(9), 903. <https://doi.org/10.3390/rs9090903>
- Lin, F.C., Chou, T.Y., Ku, W.Y., Chung, L.K., Wang, C.J. 2018. Storage and processing of massive remote sensing images using a novel cloud computing platform. *GIScience Remote Sens.*, 50(3), 322-336. <https://doi.org/10.1080/15481603.2013.810976>
- Liu, X., Fatoyinbo, T.E., Thomas, N.M., Guan, W.W., Zhan, Y., Mondal, P., Lagomasino, D., Simard, M., Trettin, C.C., Deo, R., Barenblitt, A. 2021. Large-scale High-resolution Coastal Mangrove Forests Mapping across West Africa with Machine Learning Ensemble and Satellite Big Data. *Front. Earth Sci.*, 8, 677. <https://doi.org/10.3389/feart.2020.560933>
- Luo, C., Zhang, X., Meng, X., Zhu, H., Ni, C., Chen, M., Liu, H. 2022. Regional mapping of soil organic matter content using multitemporal synthetic Landsat 8 images in Google Earth Engine. *Catena*, 209(1), 105842. <https://doi.org/10.1016/j.catena.2021.105842>
- Madonsela, S., Cho, M.A., Mathieu, R., Mutanga, O., Ramoelo, A., Kaszta, Z., Van De Kerchove, R., Wolff, E. 2017. Multi-phenology WorldView-2 imagery improves remote sensing of savannah tree species. *Int. J. Appl. Earth Obs. Geoinf.*, 58, 65-73. <https://doi.org/10.1016/j.jag.2017.01.018>
- Magidi, J., Nhamo, L., Mpandeli, S., Mabhaudhi, T., 2021. Application of the random forest classifier to map irrigated areas using google earth engine. *Rem. Sens.*, 13(5), 1-15. <https://doi.org/10.3390/rs13050876>
- Mahdianpari, M., Jafarzadeh, H., Granger, J.E., Mohammadimanesh, F., Brisco, B., Salehi, B., Homayouni, S., Weng, Q. 2020. A large-scale change monitoring of wetlands using time series Landsat imagery on Google Earth Engine: a case study in Newfoundland. *GIScience & Remote Sensing*, 57(8), 1102-1124. <https://doi.org/10.1080/15481603.2020.1846948>
- Montaño, R.A.N.R., Sanquetta, C.R., Wojciechowski, J., Mattar, E., Corte, A.P.D., Todt, E. 2017. Artificial Intelligence Models to Estimate Biomass of Tropical Forest Trees. *Polibius*, 56, 29-37.
- Morell-Monzó, S., Sebastiá-Frasquet, M.T., Estornell, J. 2021. Land Use Classification of VHR Images for Mapping Small-Sized Abandoned Citrus Plots by Using Spectral and Textural Information. *Remote Sens.*, 13, 681. <https://doi.org/10.3390/rs13040681>
- Muñoz J., Milera S., Romero C., Brizuela A. 2005. Bosques nativos y selvas ribereñas en la Provincia de Entre Ríos. *INSUGEO Miscelánea* 14, 169-182. Tucumán. Argentina.
- Naboureh, A., Li, A., Bian, J., Lei, G., Amani, M. A Hybrid Data Balancing Method for Classification of Imbalanced Training Data within Google Earth Engine: Case Studies from Mountainous Regions. *Remote Sens.*, 12, 3301. <https://doi.org/10.3390/rs12203301>
- Nascimento, J.L., Campos, I.B. 2011. *Atlas da fauna brasileira ameaçada de extinção em unidades de conservação federais*. ICMBIO. Brasília, 276 pp.
- Oszust, J.D., Wilson, M.G., Wingeyer, A.B, Seehus, M.S., Sasal, M.C., Gabioud, E.A., van Opstal, N.V. 2019. Régimen de precipitaciones en el Centro Oeste de Entre Ríos. *Revista Científica Agropecuaria*, 23(1): 27-34.
- Oyarzabal, M., Clavijo, J., Oakley, L., Biganzoli, F., Tognetti, P., Barberis, I., Maturo, H.M., Aragón, R., Campanello, P.I., Prado, D., Oesterheld, M., & León, R.J. 2018. Unidades de vegetación de la Argentina. *Ecología Austral*, 28(1), 040-063. <https://doi.org/10.25260/EA.18.28.1.0.399>
- Paruelo, J.M., Jobbágy, E.G., Laterra, P. 2014. Bases conceptuales del ordenamiento territorial rural. En: Paruelo, J.M., Jobbágy, E.G., Laterra, P., Dieguez, H., García-Collazo, M.A., Panizza, A. (Eds.), *Ordenamiento Territorial Rural. Conceptos, métodos y experiencias*, pp. 10-31. Universidad de Buenos Aires, Ministerio de Agricultura, Ganadería y Pesca, Organización de las Naciones Unidas para la Alimentación y la Agricultura. Buenos Aires, Argentina.

- Pérez-Cutillas, P., Pérez-Navarro, A., Conesa-García, C., Zema, D.A., Amado-Álvarez, J.P. 2023. What is going on within google earth engine? A systematic review and meta-analysis. *Remote Sensing Applications: Society and Environment*, 29, 100907. <https://doi.org/10.1016/j.rsase.2022.100907>
- Plan Mapa de Suelos Provincia de Entre Ríos. 1980. *Suelos y erosión de la Provincia de Entre Ríos*. Tomo 1. INTA EEA Paraná, Serie Relevamiento de Recursos Naturales. Proyecto PNUD/FAO/ INTA Arg 68/526. 109 pp
- Rodríguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Olmo, M., Rigol-Sánchez, J.P. 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-104. <https://doi.org/10.1016/j.isprs.2011.11.002>.
- Sabattini, R.A., Wilson, M.G., Muzzachiodi, N., Dorsch, A.F. 1999. Guía para la caracterización de agroecosistemas del centro-norte de Entre Ríos. *Revista Científica Agropecuaria*, 3, 7-19.
- Sabattini, R.A., Sione, S., Ledesma, S.G., Muracciole, B., Cottani, F., Fortini, C. 2008. Análisis de la diversidad florística y de los tipos productivos del pastizal natural en un monte nativo bajo pastoreo rotativo (Entre Ríos, Argentina). *Revista Científica Agropecuaria*, 12(1), 5-13.
- Sabattini, R.A., Ledesma, S., Brizuela, A., Sabattini, J.A., Diez, J.M. 2010. Metodología y Criterios para el ordenamiento territorial de bosques nativos de Entre Ríos. En: *III Jornadas RedVITEC*, 25-26 noviembre 2010, Mendoza, Argentina. Mendoza: IMD. 14 pp.
- Sabattini, J.A., Sabattini, R.A., Ledesma, S. 2015. Caracterización del bosque nativo del centro norte de Entre Ríos (Argentina). *Agrociencia Uruguay*, 19(2), 8-16. <https://doi.org/10.31285/AGRO.19.296>
- Seidlova, A., Kudelcikova, M., Mihalik, J.; Rekus, D. 2021. Interpretation of Remote Sensing Imagery. *IOP Conf. Series: Earth and Environmental Science* 906. IOP Publishing. <https://doi.org/10.1088/1755-1315/906/1/012070>
- Sharma, L.K., Gupta, R., Fatima, N. 2022. Assessing the predictive efficacy of six machine learning algorithms for the susceptibility of Indian forests to fire. *International Journal of Wildland Fire.*, 31(8), 735-758. <https://doi.org/10.1071/WF22016>
- Shetty, S., Gupta, P.K., Belgiu, M., Srivastav, S.K. 2021. Assessing the effect of training sampling design on the performance of machine learning classifiers for land cover mapping using multi-temporal remote sensing data and google earth engine. *Rem. Sens.* 13(8), 1433. <https://doi.org/10.3390/rs13081433>.
- Singha, M., Dong, J., Sarmah, S., You, N., Zhou, Y., Zhang, G., Dougherty, R., Xiao, X. 2020. Identifying floods and flood-affected paddy rice fields in Bangladesh based on Sentinel-1 imagery and Google Earth Engine. *ISPRS J. Photogrammetry Remote Sens.* 166, 278-293. <https://doi.org/10.1016/j.isprs.2020.06.011>
- Stromann, O., Nascetti, A., Yousif, O., Ban, Y. 2020. Dimensionality reduction and feature selection for object-based land cover classification based on sentinel-1 and sentinel-2 time series using google earth engine. *Rem. Sens.*, 12(1), 76. <https://doi.org/10.3390/rs12010076>
- Suryono, H., Kuswanto, H., Iriawan, N. 2022. Rice phenology classification based on random forest algorithm for data imbalance using Google Earth engine. *Procedia Computer Science*, 197, 668-676. <https://doi.org/10.1016/j.procs.2021.12.201>.
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., Brisco, B. 2020. Google Earth Engine for geo-big data applications: a meta-analysis and systematic review. *ISPRS J. Photogrammetry Remote Sens.* 164, 152-170. <https://doi.org/10.1016/j.isprs.2020.04.001>.
- Townsend, J.T. 1971. Theoretical analysis of an alphabetic confusion matrix. *Percept. Psychophys.* 9(1), 40-50. <https://doi.org/10.3758/BF03213026>
- Tran, K.H., Zhang, H.K., McMaine, J.T., Zhang, X., Luo, D. 2022. 10 m crop type mapping using Sentinel-2 reflectance and 30 m cropland data layer product. *International Journal of Applied Earth Observation and Geoinformation*, 107, 102692. <https://doi.org/10.1016/j.jag.2022.102692>.
- Viña, A., Liu, W., Zhou, S., Huang, J., Liu, J. 2016. Land surface phenology as an indicator of biodiversity patterns. *Ecological Indicators*, 64: 281-288. <https://doi.org/10.1016/j.ecolind.2016.01.007>
- Zerda, H.R., Tiedemann, J.L. 2010. Dinámica temporal del NDVI del bosque y pastizal natural en el Chaco Seco de la Provincia de Santiago del Estero, Argentina. *Ambiència Guarapuava*, 6(1), 13-24. <https://doi.org/10.5777/1808-02512010000300001>
- Zhao, Y., Zhu, W., Wei, P., Fang, P., Zhang, X., Yan, N., Liu, W., Zhao, H., Wu, Q. 2022. Classification of Zambian grasslands using random forest feature importance selection during the optimal phenological period. *Ecological Indicators*, 135, 108529. <https://doi.org/10.1016/j.ecolind.2021.108529>
- Zhao, X., Xia, H., Pan, L., Song, H., Niu, W., Wang, R., Li, R., Bian, X., Guo, Y., Qin, Y. 2021. Drought monitoring over Yellow river basin from 2003–2019 using reconstructed MODIS land surface temperature in google earth engine. *Remote Sens.*, 13, 3748. <https://doi.org/10.3390/rs13183748>.