

Modelos predictivos para la estimación de biomasa de *Spartina argentinensis*

Predictive models for assessing *Spartina argentinensis* biomass

Modelos predictivos para estimar a biomassa de *Spartina argentinensis*

Jozami, Emiliano¹ ; Di Leo, Néstor² ; Barbona, Ivana³ ; Feldman, Susana¹ 

¹ Consejo de Investigaciones de la Universidad Nacional de Rosario, CP: 2000, Rosario, Argentina

² Centro de Estudios Territoriales, Facultad de Ciencias Agrarias, UNR, CP: s2125zaa Zavalla, Argentina

³ Cátedra de Estadística, Facultad de Ciencias Agrarias, UNR, CP: s2125zaa Zavalla, Argentina

ejozami@unr.edu.ar

DOI: <https://doi.org/10.35305/agro45.e047>

Recibido: Agosto 2024 Aceptado: Abril 2025

Resumen

En Argentina, los pastizales naturales cubren vastas áreas, prestando importantes servicios ecosistémicos. Tradicionalmente, la ganadería ha sido la principal actividad productiva en estos ambientes, con el uso del fuego como práctica de manejo habitual. Aunque las quemadas estimulan el rebrote de pastos con mejor calidad forrajera, también resultan en la emisión de CO_{2eq} a la atmósfera, lo que plantea desafíos ambientales. Ante la creciente demanda de fuentes de energía renovable, los pastizales naturales, manejados en sistemas ganaderos con quemadas frecuentes, se presentan como una alternativa sustentable para la producción de bioenergía. En la provincia de Santa Fe, los espartillares dominados por *Spartina argentinensis* en los Bajos Submeridionales, abarcando más de dos millones de hectáreas, tienen un elevado potencial para la producción de bioenergía sin comprometer la biodiversidad existente. Este trabajo se centra en el desarrollo y evaluación de modelos predictivos de biomasa de *S. argentinensis* utilizando imágenes espectrales obtenidas mediante drones. Se desarrollaron modelos de regresión lineal múltiple y de clasificación, considerando variables espectrales, sitio y estaciones del año, para predecir la biomasa total y sus fracciones verdes y senescentes. Los modelos obtenidos para estimar la biomasa total del espartillo permitieron explicar hasta el 62% de su variabilidad. Las fracciones de la biomasa verde y senescente pudieron ser predichas con mayor precisión, presentando un R² de 66% para cada una de ellas. Estos hallazgos destacan el potencial de la tecnología de teledetección para optimizar la planificación y manejo sostenible de recursos biomásicos en los pastizales argentinos.

Palabras clave: biomasa; pastizales; Van multiespectral

Abstract

Vast areas of Argentina are covered by rangelands, which provide important ecosystem services. Traditionally, livestock farming has been the main productive activity in these environments, with the use of fire as a common management practice. Although burning stimulates the regrowth of grasses with better forage quality, it also poses environmental challenges due to the emission of CO_{2eq} into the atmosphere. In response to the growing demand for renewable energy sources, rangelands under livestock production systems with frequent burning present a sustainable alternative for bioenergy production. In the province of Santa Fe, rangelands dominated by *Spartina argentinensis* in the Bajos Submeridionales region, which covers more than two million hectares, have high potential for bioenergy production without compromising the existing biodiversity. This work focuses on the development and evaluation of predictive models for *S. argentinensis* biomass using spectral images obtained by drones. Multiple linear regression and classification models were developed, considering spectral variables, site, and seasons, to predict total biomass and its green and senescent fractions. The models obtained to estimate the total biomass of *Spartina* explained up to 62% of its variability. The green and senescent biomass fractions were predicted with greater accuracy, showing an R² of 66% for both. These findings highlight the potential of remote sensing technology to optimize the planning and sustainable management of biomass resources in Argentine grasslands.

Keywords: biomass; rangelands; Van multiespectral

Resumo

Na Argentina, as pastagens naturais cobrem vastas áreas, prestando importantes serviços ecossistêmicos. Tradicionalmente, a pecuária tem sido a principal atividade produtiva nesses ambientes, com o uso do fogo como prática comum de manejo. Embora as queimadas estimulem o rebrote de gramíneas com melhor qualidade forrageira, elas também resultam na emissão de CO₂eq na atmosfera, o que apresenta desafios ambientais. Diante da crescente demanda por fontes de energia renovável, as pastagens naturais, manejadas em sistemas pecuários com queimadas frequentes, apresentam-se como uma alternativa sustentável para a produção de bioenergia. Na província de Santa Fe, as pastagens de esparto dominadas por *Spartina argentinensis* nos Baixos Submeridionais, cobrindo mais de dois milhões de hectares, têm um elevado potencial para a produção de bioenergia sem comprometer a biodiversidade existente. Este trabalho foca no desenvolvimento e avaliação de modelos preditivos de biomassa de *S. argentinensis* utilizando imagens espectrais obtidas por drones. Foram desenvolvidos modelos de regressão linear múltipla e de classificação, considerando variáveis espectrais, locais e sazonais, para prever a biomassa total e suas frações verdes e senescentes. Os modelos obtidos para estimar a biomassa total de *Spartina* permitiram explicar até 62% de sua variabilidade. As frações de biomassa verde e senescente puderam ser previstas com maior precisão, apresentando um R² de 66% para cada uma. Essas descobertas destacam o potencial da tecnologia de sensoriamento remoto para otimizar o planejamento e manejo sustentável dos recursos de biomassa nas pastagens argentinas.

Palavras-chave: biomassa; pastagens; Van multiespectral

Introducción

Los pastizales naturales son uno de los principales tipos de cobertura continental de las zonas libre de hielo y se estima que abarcan globalmente 1.850 millones de ha ([Godde et al., 2020](#)). En la Argentina el censo nacional agropecuario del 2018 reportó 71 millones de ha ocupados por pastizales ([INDEC, 2021](#)). Fernandez y Busso ([2017](#)) indicaron que en Argentina, el área ocupada por pastizales áridos y semiáridos, abarca alrededor de 200 millones de ha lo que representa dos tercios de la superficie nacional.

En estos ecosistemas, la actividad ganadera de distintas especies es la principal actividad productiva, en un sistema en el cual el fuego es una práctica de manejo habitual, con un período de recurrencia entre quemados que oscila entre uno y tres años ([Levine, 1991](#)). Esta práctica está fundamentada en que la remoción de la biomasa por las quemados estimula el crecimiento de rebrotes de mayor calidad forrajera tanto en digestibilidad como en contenido de proteínas ([Massa et al., 2017](#)). Por otra parte, la remoción de la biomasa mediante incendios prescritos facilita las tareas de manejo del ganado, que se suele agrupar en las zonas recientemente quemados. Cabe resaltar que esta práctica emite más CO₂eq a la atmósfera que el que fija la vegetación tal como lo ha reportado el IPCC ([2019](#)).

Verón et al. ([2012](#)) evaluaron a escala global, cuánta energía eléctrica podría producirse si se derivase a su producción, la biomasa quemada anualmente encontrando que se combustionan en promedio en el mundo 8,3 EJ anualmente. En el caso de Argentina, según estos autores, la energía eléctrica que se podría generar a partir de la biomasa que se quema superaría ampliamente el consumo promedio de electricidad del país, que es de aproximadamente 0,4 EJ por año. Los bajos submeridionales puntualmente, han sido reportados como una zona con altas frecuencias de quemados ([Pinilla Vargas, Diana, 2012](#)).

La creciente demanda de fuentes de energía renovable ha llevado a la exploración de recursos biomásicos que pueden ser aprovechados de manera sostenible. En este contexto, los pastizales naturales manejados en sistemas ganaderos con quemados frecuentes son una alternativa sustentable desde múltiples perspectivas ([Tilman et al., 2009](#); [Tilman, 2009](#)) ya que su uso no compete ni directa ni indirectamente con la producción de alimentos.

En la provincia de Santa Fe, los espartillares dominados por *Spartina argentinensis* en los Bajos Submeridionales abarcan más de dos millones de ha. Estos presentan un elevado potencial para la producción de bioenergía ([Jozami et al., 2013](#)). Además de su vasta superficie, ofrecen la ventaja de un manejo compatible con su uso actual en planteos ganaderos, permitiendo reemplazar la quema por la cosecha de la biomasa sin comprometer la biodiversidad de vertebrados ni de la vegetación allí presentes ([Sosa et al., 2019](#)).

La estimación precisa de la biomasa disponible es un factor crítico para el desarrollo de proyectos bioenergéticos viables. En este sentido, la utilización de tecnologías avanzadas como las cámaras espectrales montadas en drones ofrece una solución innovadora para evaluar la disponibilidad de biomasa de manera eficiente y a gran escala ([Villoslada Peciña et al., 2021](#)). Mediante el desarrollo de modelos predictivos basados en datos espectrales, es posible extrapolar estas estimaciones a mayores áreas geográficas mediante imágenes satelitales, lo que facilita la planificación y optimización de la cosecha ([Byrd et al., 2018](#)).

Muchos autores han evaluado pastizales de diversas especies intentando establecer correlaciones entre bandas espectrales e índice derivados de éstas, obtenidos a partir de imágenes satelitales y la cantidad de biomasa cuantificada a campo ([Todd et al., 1998](#); [Porter et al., 2014](#); [Wang et al., 2019](#); [Yang and Guo, 2014](#)). En general las correlaciones obtenidas no son tan elevadas para este tipo de comunidades y el principal motivo es que una parte significativa de la biomasa, se encuentra como biomasa senescente (tejidos necrosados sin actividad fotosintética).

Dado que la biomasa senescente tiene características espectrales que la hacen menos disímil al suelo, es más complejo encontrar índices espectrales que sean sensibles a la cantidad de biomasa senescente. Algunos trabajos han evaluado diversos índices espectrales y su correlación con la biomasa de especies emparentadas a *S. argentinensis* o incluso en la misma especie ([Hardisky et al., 1984](#); [Gross et al., 1991](#); [González Trilla et al., 2016](#)).

El uso de drones presenta ventajas sobre las imágenes satelitales de alta resolución ya que permite una mayor flexibilidad en la adquisición de datos, mejor resolución espacial y temporal y la posibilidad de captar imágenes en condiciones atmosféricas que podrían afectar la calidad de los datos satelitales. El objetivo de este trabajo fue desarrollar y evaluar modelos predictivos de biomasa de *Spartina argentinensis* empleando imágenes espectrales de cámaras montadas en un dron.

Materiales y Métodos

Zona de trabajo

Se trabajó en un espartillar de la Reserva de Usos Múltiples Federico Wildermuth (32° 0,5' S; 61° 24,9' O) en tres fechas, con 10 muestras cada una: 15/3/2018; 7/9/2018 y 20/2/2019 y en un espartillar de un establecimiento privado (32° 05' S 61° 21' O) en dos fechas, con 30 muestras cada una: 09/10/2019 y 12/03/2020.

En cada fecha se colocaron 10 puntos de muestreo distanciados aproximadamente a 50 m entre sí y delimitados con 4 estacas a las cuales se sujetó una tela amarilla de 50 cm x 100 cm, fácilmente visibles desde el dron ([Figura 1](#)). En las primeras tres fechas, en Wildermuth la cosecha de biomasa se realizó siempre al oeste de la tela, luego de producido el vuelo en el cual se obtuvieran las imágenes. En el establecimiento privado, donde se procesaron 30 muestras por día de trabajo (10 waypoints), la biomasa se cosechó al norte, al este y al oeste de la tela en cada waypoint. El punto sur no se utilizó para la cosecha, ya que se destinó al tránsito durante las operaciones de colocación de las telas.



Figura 1: Área de muestreo al oeste del paño (izquierda); Parcelas de muestreo en Wildermuth (centro) e imagen del paño y el sector que representaría al área cosechada (derecha).

En las últimas dos fechas, se cosecharon 3 muestras (este, norte y oeste) por zona de muestreo como se puede apreciar en la [figura 2](#).




Figura 2: Zona de trabajo en el espartillar delimitado por el rectángulo negro (izquierda) y ejemplo de un paño con las tres zonas de muestreo.

Variables explicativas obtenidas desde el dron

Se utilizó un dron eBee sensefly de ala fija, realizando un vuelo a 121 m (resolución espacial de 8 cm) y una cámara modelo Parrot Sequoia con 4 canales espectrales ([Figura 3](#)): verde, rojo, borde rojo e Infra rojo cercano.




Figura 3: Plataforma de vehículo aéreo no tripulado (eBee SQ). (a); cámara multispectral (b); sensor de luz solar (c).



La [tabla 1](#) resume las variables explicativas: 4 bandas espectrales y 14 índices derivados de las mismas con sus nombres en inglés, la traducción al español y la cita correspondiente. Se presentó además la ecuación de cada índice.

Tabla 1: Bandas e índices espectrales obtenidos del espantillo desde el dron.

Banda/Índice espectral	Nombre en español	Ecuación/rango de banda (nm)	Cita
Verde (Gr)		530-570	
Rojo (Rd)		640-680	
Borde Rojo (Re)		730-740	
Infrarrojo cercano (NIR)		770-810	
1. NDVI: <i>normalized difference vegetation index</i>	Índice de vegetación de diferencia normalizada	$(\text{NIR}-\text{Rd})/(\text{NIR}+\text{Rd})$	(Rouse et al., 1974)
2. NGRDI: <i>Normalized green red difference index</i>	Índice de diferencia verde-rojo normalizado	$(\text{Gr}-\text{Rd})/(\text{Gr}+\text{Rd})$	(Hunt et al., 2011)
3. NDRE: <i>normalized difference Red Edge index</i>	Índice Normalizado Diferencial de Borde Rojo	$(\text{NIR}-\text{Re})/(\text{NIR}+\text{Re})$	(Barnes et al., 2000)
4. SR: <i>Simple Ratio</i>	Índice de Relación Simple	NIR/Red	(Jordan, 1969)
5. GNDVI: <i>Green normalized difference vegetation index</i>	Índice de vegetación de diferencia normalizada Verde	$(\text{NIR}-\text{Gr})/(\text{NIR}+\text{Gr})$	(Louhaichi et al., 2001)
6. GRVI: <i>green-red vegetation index</i>	Índice de vegetación Verde-Rojo	NIR/Gr	(Sripada et al., 2005)
7. CI _{green} : <i>chlorophyll index Green</i>	Índice de clorofila Verde	$(\text{NIR}/\text{Gr})-1$	(Gitelson et al., 2003)
8. CI _{re} : <i>chlorophyll index Red Edge</i>	Índice de clorofila Borde Rojo	$(\text{NIR}/\text{Re})-1$	(Gitelson et al., 2003)
9. PSRI: <i>plant senescence reflectance index</i>	Índice de reflectancia de senescencia de las plantas	$(\text{Rd}-\text{Gr})/\text{NIR}$	(Merzlyak et al., 1999)
10. OSAVI: <i>optimized soil adjusted vegetation index</i>	Índice de Vegetación Ajustado de Suelo optimizado	$(1+0,16)+((\text{NIR}-\text{Rd})/(\text{NIR}+\text{Rd}+0,16))$	(Rondeaux et al., 1996)
11. TCARI: <i>transformed chlorophyll absorption reflectance index</i>	Índice de reflectancia en absorción de clorofila transformada	$3*((\text{Re}-\text{Rd})-0,2*(\text{Re}-\text{Gr})*(\text{Re}/\text{Rd}))$	(Daughtry, 2000)
12. TCARI/OSAVI	-	xi/x	(Haboudane et al., 2002)
13. Meris CI: <i>medium resolution imaging spectrometer - cyanobacteria index</i>	Espectrómetro de imágenes de resolución media - índice de cianobacterias	$(\text{NIR}-\text{Re})/(\text{Re}-\text{Rd})$	(Dash y Curran, 2004)
14. NDWI: <i>normalized difference water index</i>	Índice normalizado diferencial de agua	$(\text{Gr}-\text{NIR})/(\text{Gr}+\text{NIR})$	(Mc Feeters, 1996)

Cosecha de biomasa

La cosecha manual de biomasa de *S. argentinensis* en los círculos de muestreo se realizó por encima de los 15-20 cm de la superficie (biomasa a menor altura no sería posible cosechar con maquinaria segadora debido a la dureza de los tejidos basales), dentro de un anillo de 1 m², ubicado a 20 cm de la tela amarilla ([Figura 1](#)). Se determinó el peso seco (72 h a 60 °C) de las dos fracciones (hojas verdes y senescentes, [Figura 4](#)).

Se realizó una caracterización ambiental en función a la información obtenida de la estación meteorológica del Sauce Viejo (31°42'S 60°50'O), provincia de Santa Fe, que fue suministrada por el Servicio Meteorológico Nacional.



Figura 4: Muestra procesada donde se observa la biomasa verde a la izquierda y la senescente a la derecha

Modelos predictivos de biomasa

Para la estimación de biomasa se emplearon dos modelos cuyas variables explicativas se detallan en la [tabla 2](#): i- un modelo de regresión lineal múltiple (RLM) y ii- un modelo con la metodología Random Forest (RF). Las variables respuestas para el modelo RF fue el cuartil de biomasa al cual pertenece la muestra y para la regresión múltiple fueron biomasa total, biomasa senescente y biomasa verde.

Para la RLM se utilizó como técnica de selección de variables la Regresión paso a paso (Stepwise) basada en el criterio de información de Akaike. Esta técnica consiste en la construcción iterativa de un modelo de regresión agregando o eliminando variables explicativas potenciales sucesivamente, probando la significancia después de cada iteración. Una vez obtenido el modelo, se evaluó su desempeño mediante los siguientes indicadores: NRMSE; R²; la eficiencia del modelo (EF) y el índice de acuerdo (d) según proponen Hao et al. (2021).

En el modelo de RF, en función de los 90 datos observados de biomasa total, se determinaron 4 grupos según de los cuartiles de dicha variable (1: biomasa total menor al 1er cuartil; 2: biomasa total entre el 1er cuartil y la mediana; 3: biomasa total entre la mediana y el 3er cuartil; y 4: biomasa total mayor al 3er cuartil).

Random forest ([Breiman, 2001](#)) es un método de árbol de regresión y clasificación no paramétrico que utiliza conjuntos (bosques) de árboles de clasificación o regresión, en el cual cada árbol selecciona y permuta subconjuntos aleatorios de variables predictoras. El

procedimiento de iteración y aleatorización acomoda respuestas no lineales, variables categóricas o continuas y valores perdidos. Este método puede manejar interacciones complejas entre variables y ha sido útil para construir modelos de productividad y biomasa de sensores remotos ([Zeng et al., 2019](#); [Ramoelo et al., 2015](#); [Gao et al., 2020](#)).

Para la fecha 9 de octubre de 2019, se corrieron tanto el modelo RF como el de regresión múltiple para biomasa total sin sitio, en un polígono con 2.277.003 píxeles.

Los modelos asignaron a cada muestra un cuartil de biomasa (1, 2, 3 ó 4) para el modelo RF, o un valor de biomasa para la regresión múltiple, en ambos casos en función de las variables explicativas. Estas variables se obtuvieron promediando los valores de todos los píxeles dentro del área de muestreo correspondiente a cada muestra. Es decir, para cada una de las 90 muestras, se calculó un único valor promedio por variable explicativa, que luego se utilizó como dato de entrada para el modelo.

Para evaluar el desempeño de los modelos, se comparó la clasificación de cada muestra (según el cuartil de biomasa asignado) con la categoría de biomasa observada en campo para el modelo RF. En el caso de la regresión múltiple, se utilizaron las clasificaciones propuestas por He et al. (2019) y Parajuli et al. (2009). Aunque se presentaron los valores predichos por los modelos a nivel de píxeles para visualizar la variabilidad intramuestra, la evaluación de la precisión de los modelos se centró exclusivamente en el valor obtenido para cada muestra, sin considerar los resultados de los píxeles dentro de ella. Finalmente, el modelo de regresión múltiple también fue modificado para clasificar los resultados predichos en cuartiles, a fin de permitir una comparación directa con las salidas del modelo RF.

Caracterización ambiental

Se realizó una caracterización de las variables climáticas en función de la serie histórica de la estación meteorológica de El Trébol dependiente del Servicio Meteorológico Nacional que es la más cercana a las zonas de cosecha (aproximadamente 35 km). Se evaluaron los promedios mensuales de temperatura máxima y mínima y de variables relacionadas a la condición hídrica: precipitaciones y almacenaje de suelo estimado mediante la metodología de Thornthwaite (1948). Estos datos fueron procesados con Rstudio para la obtención de gráficos de boxplot mostrando la dispersión histórica a las cuales se solaparon los valores de los años 2018, 2019 y 2020 durante los cuales se realizaron las cosechas.




Figura 5: imagen satelital obtenida de Google Earth en la cual se observa la distancia de los sitios de muestreo hasta la estación meteorológica con la cual se realizó la caracterización ambiental.

Resultados

Caracterización ambiental

Las [figuras 6 y 7](#) muestran el valor medio mensual de almacenaje de agua en el suelo y precipitaciones, respectivamente, en la estación meteorológica de El Trébol ($32^{\circ} 18' S$ $61^{\circ} 40' O$) y su comparación con la serie histórica. La primera cosecha (marzo de 2018) se realizó en condiciones de sequía con un valor mínimo histórico de almacenaje, levemente superior a los 110 mm como media mensual. Esta situación se revirtió con las precipitaciones otoñales, llegando a la primavera (segunda fecha de cosecha) con valores de almacenaje coincidentes con la mediana en el mes de septiembre de 2019. La última cosecha en Wildermuth se dio con una condición hídrica alta (almacenaje cercano al 3er cuartil). En el establecimiento privado, la cosecha primaveral de 2019 se dio con un almacenaje ubicado dentro de valores cercanos a la mediana, mientras que en 2020 las condiciones de agua fueron menores al 1er cuartil.




Figura 6: Almacenaje de agua en el suelo en función de la serie histórica de El Trébol (1991 hasta 2020). Las flechas verdes indican los momentos de cosecha en Wildermuth y las azules en el establecimiento privado. Los puntos azules indican la situación de cada año facilitando la comparación con la serie histórica.




Figura 7: Precipitaciones en función de la serie histórica de El Trébol (1991 hasta 2020). Las flechas verdes indican los momentos de cosecha en Wildermuth y las azules en el establecimiento privado. Los puntos azules indican la situación de cada año facilitando la comparación con la serie histórica.

Las [figuras 8 y 9](#) muestran la situación ambiental respecto a la serie histórica de las temperaturas máximas y mínimas, respectivamente. La primera cosecha (marzo de 2018) se realizó en condiciones de altas temperaturas respecto a la media histórica. Estas altas temperaturas

prevalecieron hasta la segunda cosecha con excepción de las máximas del mes de septiembre. La cosecha de febrero de 2019 también fue en condiciones de alta temperatura con relación a la mediana histórica. Las temperaturas del invierno de 2019 fueron bajas. En septiembre de este año se alcanzaron altas temperaturas máximas (25 °C de promedio) y octubre (mes de cosecha en el establecimiento privado) transcurrió en condiciones normales para la época del año. El primer trimestre de 2020 registró temperaturas normales para esa época del año.




Figura 8: Temperatura máximas en función de la serie histórica de El Trébol (1991 hasta 2020). Las flechas verdes indican los momentos de cosecha en Wildermuth y las azules en el establecimiento privado. Los puntos azules indican la situación de cada año facilitando la comparación con la serie histórica.




Figura 9: Temperaturas mínimas en función de la serie histórica de El Trébol (1991 hasta 2020). Las flechas verdes indican los momentos de cosecha en Wildermuth y las azules en el establecimiento privado. Los puntos azules indican la situación de cada año facilitando la comparación con la serie histórica.

Modelos predictivos de biomasa

Las fracciones de biomasa cosechada en las cinco fechas de cosecha pueden observarse en la [figura 10](#). Se observa con claridad que, en la estación primaveral, la biomasa verde presenta valores más bajos en relación a la biomasa total al compararlos con la estación otoñal.




Figura 10: Fracciones de biomasa de *S. argentinensis* para las cinco fechas de cosecha en los dos sitios

Las variables explicativas seleccionadas por cada modelo pueden observarse en la [tabla 2](#).

Tabla 2: variables empleadas por cada modelo.

	Estación (variable dummy)	Sitio (Variable dummy)	Banda verde	Banda roja	Banda borde rojo	Banda NIR	NDWI	OSAVI
Biomasa total con sitio	x	x	x	x	x	x	x	x
Biomasa total sin sitio	x		x	x		x	x	x
Biomasa verde con sitio	x	x	x	x	x		x	x
Biomasa verde sin sitio	x		x	x		x	x	x
Biomasa senescente con sitio	x	x	x			x	x	
Biomasa senescente sin sitio	x		x	x	x	x	x	x
Modelo cualitativo Random Forest	x		x	x	x	x	x	x

La [figura 11](#) muestra las regresiones de los modelos de RLM con y sin la inclusión del sitio como variable cualitativa. Debido a que el R^2 baja entre 0,15 y 0,25 al sacar el sitio, ya sea por el tipo de suelo o por las condiciones meteorológicas acontecidas próximas a las fechas de cosecha, éste explica entre un 15 y 25% de la variabilidad de las distintas fracciones de biomasa.




Figura 11: Modelos predictivos de biomasa total, senescente y verde con la inclusión del sitio como variable cualitativa (izquierda) y sin la inclusión del sitio (derecha)

Los estimadores del desempeño de los seis modelos se pueden observar en la [tabla 3](#). En todos ellos se observa que la presencia del sitio como variable cualitativa mejora el desempeño de los modelos. La clasificación según cada índice de desempeño se realizó tomando como referencia las categorizaciones propuestas He et al., ([2019](#)) y Parajuli et al., ([2009](#)).

Tabla 3: Indicadores de desempeño de los modelos predictivos de biomasa.

sitio	Fracción de biomasa	R2		NRMSE		EF		d	
		valor	clasificación	valor	clasificación	valor	clasificación	valor	clasificación
con sitio	Biomasa total	0,62	bueno	0,24	regular	0,62	bueno	0,87	bueno
	Biomasa senescente	0,66	bueno	0,3	regular	0,66	bueno	0,89	bueno
	Biomasa verde	0,66	bueno	0,27	regular	0,66	bueno	0,89	bueno
sin sitio	Biomasa total	0,41	regular	0,3	regular	0,41	regular	0,74	regular
	Biomasa senescente	0,51	bueno	0,36	malo	0,51	bueno	0,81	bueno
	Biomasa verde	0,5	bueno	0,33	malo	0,5	bueno	0,81	bueno

En la [figura 12](#) se observa la variabilidad intramuestra de los cuartiles predichos por el modelo RF para 3 muestras en el 9 de octubre de 2019. El modelo RF pudo predecir correctamente las 90 muestras, coincidiendo el cuartil de biomasa predicho con el observado. Debido a que las variables explicativas se obtuvieron con una resolución espacial mayor a las de la zona de muestreo (píxel de 8x8 cm vs círculo de 1 m²), se puede observar para las 3 muestras ampliadas en la [figura 12](#) en las cuales la biomasa total estaba dentro del grupo 3 (entre 6951 y 8545 kg por ha), los valores predichos por el modelo RF en cada uno de los pixeles que componen cada muestra.




Figura 12: Resultado del modelo RF corrido en pixels de 8 cm en el que se observan delimitadas en círculos negros las 30 muestras. A la izquierda se pueden apreciar 3 muestras cuya clasificación es 3 (Azul).

En la [figura 13](#) se analiza de forma análoga al modelo RF, el polígono con las mismas muestras que en la figura 12. Al ampliar las mismas tres muestras, se puede apreciar que el nivel de acierto es menor en este modelo lo que resulta consistente debido al bajo R² de dicho modelo. No obstante, resulta notable que ambos modelos delimitaron de manera similar las zonas con mayor cantidad de biomasa (aquellas zonas de color verde).




Figura 13: Resultado del modelo RLM sin sitio corrido en pixeles de 8 cm en el que se observan delimitadas en círculos negros las 30 muestras. A la izquierda se pueden apreciar 3 muestras cuya clasificación es 3 (Azul).

Discusión

Se desarrollaron modelos de estimaciones de las fracciones de biomasa de *Spartina argentinensis* con valores aceptables de desempeño predictivo, al menos al compararlo con otros trabajos sobre comunidades de especies del género *Spartina* ([Trilla et al., 2010](#); [González Trilla et al., 2016](#)). Cabe aclarar que en los trabajos mencionados no se realizaron modelos de RLM sino que se obtuvieron correlaciones entre índices espectrales y la biomasa. En las cosechas primaverales los porcentajes de biomasa senescente resultaron ser mayores a los otoñales (entre 70 y 80% en primavera vs 40 a 55% en otoño).

En los últimos años se han publicado muchos resultados abordando el uso de drones para estimar biomasa de diversas comunidades. En una extensa revisión bibliográfica, Poley y McDermid ([2020](#)) encontraron que para muchos ambientes la biomasa puede ser predicha tanto directamente como indirectamente a través de la estimación de la altura de los canopeos. En la misma línea, otros autores obtuvieron buenas estimaciones en pasturas mixtas de *Phleum pratense* y *Festuca pratensis* con drones utilizando como variable explicativa a la altura del canopeo ([Viljanen et al., 2018](#)) obtenida mediante estimación. Estos últimos autores, trabajaron con modelos de regresión lineal múltiple y modelos de Random Forest encontrando para ambos casos los mejores resultados al combinar índices de vegetación, altura del canopeo y reflectancia de bandas en rojo verde y azul.

Di Leo et al ([2022](#)) analizaron la misma comunidad de este trabajo, comparando los datos de reflectancia obtenidos del dron con datos de un espectrofotómetro de alta resolución espectral a campo. Evaluaron las firmas espectrales en función de la estación de crecimiento de otoño y primavera y desarrollaron un índice espectral. Hallaron menor cantidad de biomasa total a mayor reflectancia en el infrarojo cercano, lo cual difiere con el patrón esperado según el cual la vegetación debería presentar mayor reflectancia en el NIR. También documentaron una baja en la reflectancia en el NIR en la estación primaveral con respecto a la otoñal, lo cual puede atribuirse a la mayor proporción de biomasa senescente (observada en esta estación) a la cual se atribuye una menor reflectancia en el NIR ([Bremer et al., 2011](#)). Según Knyazikhin et al. ([2013](#)) las plantas con hojas aciculares (como es el caso del espartillo) absorben más radiación

NIR que las plantas de hoja ancha, lo cual podría explicar en parte esta relación inversa entre la biomasa y la reflectancia en esta banda.

Trilla et al. (2010) reportaron, en cosechas de *S. densiflora* realizadas entre 2005 y 2007 en las costas de la laguna de Mar Chiquita, valores máximos de biomasa verde en el mes de febrero y mínimos entre agosto y octubre en coincidencia con nuestros resultados para *S. argentinensis*. Si bien las especies son cercanas desde un punto de vista taxonómico, las fracciones de biomasa aparentemente no tendrían comportamientos ecofisiológicos semejantes respecto de la proporción de biomasa total representada por la biomasa verde, ya que para *S. densiflora* ambas variables están altamente correlacionadas (0,99) mientras que en el caso de *S. argentinensis* los valores de correlación entre biomasa total y biomasa verde son más bajos (0,63). Los ambientes de ambas comunidades también podrían tener influencia en estas diferencias puesto que en Mar Chiquita hay inundación por mareas mientras que en los espartillares aquí analizados, hay inundaciones frecuentes por el drenaje pobre luego de precipitaciones.

El tiempo desde la última quema es otro factor que afecta a esta correlación ya que, si el espartillar fue quemado recientemente, la fracción de biomasa total correspondiente a biomasa verde será mayor.

Si bien lo ideal sería que las variables explicativas evaluadas (bandas espectrales e índices espectrales derivados de las mismas) no interaccionen con el sitio, a fin de poder extrapolar los modelos a escalas más grandes con imágenes satelitales, el efecto sitio resultó significativo para todas las fracciones de biomasa.

Byrd et al. (2018) obtuvieron modelos predictivos de biomasa para distintas especies dominantes de pantanos salinos de las fronteras de EEUU. Empleando la técnica de bosques aleatorios obtuvieron valores de R^2 de 0,58 para estimar biomasa verde y dicho valor descendió a 0,45 al quitar la variable sitio lo cual resulta coincidente con los resultados obtenidos en este trabajo. Si bien los valores de R^2 obtenidos en este trabajo para *S. argentinensis* fueron superiores a los de Byrd et al. (2018), el desempeño analizado a partir del NRSME resulta menor.

Los modelos aquí generados podrán ser validados en trabajos futuros para poder diferenciar con herramientas de teledetección, zonas con abundante cantidad de biomasa de espartillo de aquellas zonas con menor cantidad.

En función de la bibliografía, el suelo seco tiene una reflectancia muy superior en la banda roja (Manzo et al., 2015) a la de la vegetación (no así el suelo húmedo cuya reflectancia se asemeja a la de la vegetación) con lo cual podría hipotetizarse que, en condiciones de varios días sin ocurrencia de precipitación, aquellas zonas con baja cobertura vegetal tendrán mayor reflectancia en el rojo que las zonas con alta densidad de espartillo cubriendo el suelo.

Conclusiones

Se realizaron dos modelos predictivos de biomasa con datos observados de 90 muestras obtenidas en dos ubicaciones y en cinco fechas de muestreo: i) un modelo cualitativo de cuatro categorías de biomasa (1 la de menor biomasa y 4 la de mayor) con la metodología Random Forest que acertó en la clasificación de la totalidad de las 90 muestras con las que se realizó el modelo; y ii) un modelo de regresión lineal múltiple.

Se corrieron ambos modelos para un polígono de 14.000 m² (más de 2 millones de píxeles) para una de las fechas y se visualizó consistencia sobre todo para las zonas de mayor biomasa lo cual permitirá, mediante el procesamiento de imágenes satelitales, delimitar zonas de mayor biomasa. Estos modelos podrán ser validados en otros espartillares de la provincia en futuros

trabajos. Los modelos de regresión lineal múltiple obtenidos, presentaron indicadores de desempeño entre regular y bueno.

Los resultados de este estudio destacan la utilidad de la teledetección mediante drones como herramienta para estimar la biomasa en ecosistemas de pastizales naturales, con un enfoque específico en los espartillares de los Bajos Submeridionales en la provincia de Santa Fe. La aplicación de modelos predictivos permitió estimar con precisión la biomasa total y sus fracciones, alcanzando coeficientes de determinación de hasta el 66% en la predicción de biomasa verde y senescente.

El uso de modelos de regresión lineal múltiple y de clasificación con Random Forest demostraron ser eficaces para capturar la variabilidad de la biomasa. En el primero se obtuvieron buenos indicadores de desempeño mientras que el segundo asignó con exactitud cada muestra al cuartil de biomasa observado.

Desde una perspectiva aplicada, estos hallazgos tienen importantes implicaciones para el manejo sostenible de los recursos biomásicos en pastizales naturales, particularmente en aquellos sistemas ganaderos donde el uso del fuego es una práctica habitual. La posibilidad de estimar biomasa de manera no destructiva y con alta resolución espacial abre nuevas oportunidades para mejorar la planificación de cosecha en función de la disponibilidad de biomasa con fines energéticos, sin comprometer la biodiversidad del ecosistema.

En conclusión, la combinación de técnicas de teledetección con metodologías de modelado avanzadas representa una estrategia prometedora para optimizar la gestión de estos espartillares, promoviendo su aprovechamiento sostenible tanto en términos productivos como ecológicos. La implementación de estas herramientas podría facilitar la toma de decisiones en sistemas ganaderos y bioenergéticos, contribuyendo al desarrollo de prácticas más eficientes y ambientalmente responsables.

Nota aclaratoria:

Este artículo científico presenta parte de los resultados de la tesis doctoral del Dr. Emiliano Jozami, titulada “Pastizales naturales como fuente de energía renovable”, realizada para optar al título de Doctor en Ciencias Agrarias por la Universidad Nacional de Rosario. Año 2023.

Declaración de Autoría (Credit):

EJ: Investigación, Análisis formal, Redacción. **NCD:** Análisis formal, Metodología. **IB:** Análisis de datos. **SRF:** Investigación, revisión y edición.

Bibliografía

BARNES, E.M.; CLARKE, T.R.; RICHARDS, S.R.; COLAIZZI, P.D.; HABERLAND, J.; KOSTRZEWSKI, M.; WALLER, P.; CHOI, C.; RILEY, E.; THOMPSON, T.; LASCANO, R.J.; LI, H.; MORAN, M.S. (2000) Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In ASA-CSSA-SSSA, ed. the fifth international conference on precision agriculture and other resource management. Bloomington, MN, USA, pp. 1–15.

BREIMAN, L. (2001) Random Forests. *Machine Learning* 45:1. 45(1), 5–32.

BREMER, D.J.; LEE, H.; SU, K.; KEELEY, S.J. (2011) Relationships between Normalized Difference Vegetation Index and Visual Quality in Cool-Season Turfgrass: II. Factors Affecting NDVI and its Component Reflectances. *Crop Science*. 51(5), 2219–2227.

BYRD, K.B.; BALLANTI, L.; THOMAS, N.; NGUYEN, D.; HOLMQUIST, J.R.; SIMARD, M.; WINDHAM-MYERS, L. (2018) A remote sensing-based model of tidal marsh aboveground carbon stocks for the conterminous United States. *ISPRS Journal of Photogrammetry and Remote Sensing*. 139, 255–271.

- DASH, J.; CURRAN, P.J. (2004) The MERIS terrestrial chlorophyll index. *International Journal of Remote Sensing*. 25(23), 5403–5413.
- DAUGHTRY, C. (2000) Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*. 74(2), 229–239.
- FERNÁNDEZ, O. A.; BUSO, C. (2017) Arid and Semiarid Rangelands of Argentina. In M. K. Gaur & V. R. Squires, eds. *Climate Variability Impacts on Land Use and Livelihoods in Drylands*. pp. 1–348.
- GAO, X.; DONG, S.; LI, S.; XU, Y.; LIU, S.; ZHAO, H.; YEOMANS, J.; LI, Y.; SHEN, H.; WU, S.; ZHI, Y. (2020) Using the random forest model and validated MODIS with the field spectrometer measurement promote the accuracy of estimating aboveground biomass and coverage of alpine grasslands on the Qinghai-Tibetan Plateau. *Ecological Indicators*. 112.
- GITELSON, A.A.; VIÑA, A.; ARKEBAUER, T.J.; RUNDQUIST, D.C.; KEYDAN, G.; LEAVITT, B. (2003) Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters*. 30(5), n/a-n/a.
- GODDE, C.M.; BOONE, R.B.; ASH, A.J.; WAHA, K.; SLOAT, L.L.; THORNTON, P.K.; HERRERO, M. (2020) Global rangeland production systems and livelihoods at threat under climate change and variability. *Environmental Research Letters*. 15(4).
- GONZÁLEZ TRILLA, G.; PRATOLONGO, P.; KANDUS, P.; BEGET, M.E.; DI BELLA, C.; MARCOVECCHIO, J. (2016) Relationship Between Biophysical Parameters and Synthetic Indices Derived from Hyperspectral Field Data in a Salt Marsh from Buenos Aires Province, Argentina. *Wetlands*. 36(1), 185–194.
- GROSS, M.F.; HARDISKY, M.A.; WOLF, P.L.; KLEMAS, V. (1991) Relationship between aboveground and belowground biomass of *Spartina alterniflora* (Smooth Cordgrass). *Estuaries*. 14(2), 180–191.
- HABOUDANE, D.; MILLER, J.R.; TREMBLAY, N.; ZARCO-TEJADA, P.J.; DEXTRAZE, L. (2002) Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*. 81(2–3), 416–426.
- HAO, S.; RYU, D.; WESTERN, A.; PERRY, E.; BOGENA, H.; FRANSSSEN, H.J.H. (2021) Performance of a wheat yield prediction model and factors influencing the performance: A review and meta-analysis. *Agricultural Systems*. 194.
- HARDISKY, M.A.; DAIBER, F.C.; ROMAN, C.T.; KLEMAS, V. (1984) Remote sensing of biomass and annual net aerial primary productivity of a salt marsh. *Remote Sensing of Environment*. 16(2), 91–106.
- HE, W.; GRANT, B.B.; SMITH, W.N.; VANDERZAAG, A.C.; PIQUETTE, S.; QIAN, B.; JING, Q., RENNIE, J. (2019) Assessing alfalfa production under historical and future climate in eastern Canada: DNDC model development and application. . 122(June 2018).
- HUNT, E.R.; DAUGHTRY, C.S.T.; Eitel, J.U.H.; Long, D.S. (2011) Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. *Agronomy Journal*. 103(4), 1090–1099.
- INDEC (2021) Censo Nacional Agropecuario 2018. Resultados definitivos. Instituto Nacional de Estadística y Censos, ed. Buenos Aires, Argentina.
- IPCC, I.P. on C.C. (2019) 2019 Refinement to the 2006 IPCC guidelines for national greenhouse gas inventories. Agriculture, forestry and other land use. 4, 824.
- JORDAN, C.F. (1969) Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*. 50(4), 663–666.

JOZAMI, E.; L. SOSA, L.; R. FELDMAN, S. (2013) *Spartina argentinensis* as feedstock for bioethanol. *Applied Technologies and Innovations*. 9(2), 37–44.

KNYAZIKHIN, Y.; SCHULL, M.A.; STENBERG, P.; MÖTTUS, M.; RAUTIAINEN, M.; YANG, Y.; MARSHAK, A.; LATORRE CARMONA, P.; KAUFMANN, R.K.; LEWIS, P.; DISNEY, M.I.; VANDERBILT, V.; DAVIS, A.B.; BARET, F.; JACQUEMOUD, S.; LYAPUSTIN, A.; MYNENI, R.B. (2013) Hyperspectral remote sensing of foliar nitrogen content. *Proceedings of the National Academy of Sciences*. 110(3).

DI LEO, N.; JOZAMI, E.; BULACIO, E.M.; RIGALLI, N.; ROMAGNOLI, M.; BARBONA, I.; PORTAPILA, M.; FELDMAN, S. (2022) Biomass Estimation of *Sporobolus spartinus* with Multispectral Images from a Fixed-Wing Unmanned Aerial Vehicle and a Spectrometer. In 2022 IEEE Biennial Congress of Argentina (ARGENCON). IEEE, pp. 1–5.

LEVINE, J.S. (1991) Global biomass burning: Atmospheric, climatic and biospheric implications.

LOUHAICHI, M.; BORMAN, M.M.; JOHNSON, D.E. (2001) Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. *Geocarto International*. 16(1), 65–70.

MANZO, C.; VALENTINI, E.; TARAMELLI, A.; FILIPPONI, F.; DISPERATI, L. (2015) Spectral characterization of coastal sediments using Field Spectral Libraries, Airborne Hyperspectral Images and Topographic LiDAR Data (FHyL). *International Journal of Applied Earth Observation and Geoinformation*. 36, 54–68.

MASSA, E.; PRADO, D.E.; FELDMAN, S.R. (2017) Efecto del fuego o el corte sobre la producción y la calidad forrajera de un pajonal dominado por *Panicum prionitis*. *Revista Argentina de Producción Animal*. 37(1), 9–20.

Mc FEETERS, S.K. (1996) The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*. 17(7), 1425–1432.

MERZLYAK, M.N.; GITELSON, A.A.; CHIVKUNOVA, O.B.; RAKITIN, V.Y. (1999) Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum*. 106(1), 135–141.

PARAJULI, P.B.; NELSON, N.O.; FREES, L.D.; MANKIN, K.R. (2009) Comparison of AnnAGNPS and SWAT model simulation results in USDA-CEAP agricultural watersheds in south-central Kansas. *Hydrological Processes*. 23(5), 748–763.

PINILLA VARGAS, DIANA, K. (2012) Influencia del clima, la vegetación y el hombre sobre la frecuencia, intensidad y distribución de los incendios en Argentina. Universidad de Buenos Aires.

POLEY, L.G.; MCDERMID, G.J. (2020) A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems. *Remote Sensing*. 12(7).

PORTER, T.F.; CHEN, C.; LONG, J. A.; LAWRENCE, R.L.; SOWELL, B.F. (2014) Estimating biomass on CRP pastureland: A comparison of remote sensing techniques. *Biomass and Bioenergy*. 66, 268–274.

RAMOELO, A.; CHO, M.A.; MATHIEU, R.; MADONSELA, S.; VAN DE KERCHOVE, R.; KASZTA, Z.; WOLFF, E. (2015) Monitoring grass nutrients and biomass as indicators of rangeland quality and quantity using random forest modelling and WorldView-2 data. *International Journal of Applied Earth Observation and Geoinformation*. 43, 43–54.

RONDEAUX, G.; STEVEN, M.; BARET, F. (1996) Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*. 55(2), 95–107.

ROUSE, J.W.; HASS, R.H.; SCHELL, J.A.; DEERING, D.W.; HARLAN, J.C. (1974) Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation.

SOSA, L.L.; JOZAMI, E.; OAKLEY, L.J.; MONTERO, G.A.; FERRERAS, L.A.; VENTURI, G.; FELDMAN, S.R. (2019) Using C4 perennial rangeland grasses for bioenergy. *Biomass and Bioenergy*. 128(July), 105299.

SRIPADA, R.P.; HEINIGER, R.W.; WHITE, J.G.; WEISZ, R. (2005) Aerial Color Infrared Photography for Determining Late-Season Nitrogen Requirements in Corn. *Agronomy Journal*. 97(5), 1443–1451.

THORNTHWAITE, C. (1948) An approach toward a rational classification of climate. *Geographical review*. 38(1), 55–94.

TILMAN, D. (2009) Carbon-Negative Biofuels. . 1598(2006).

TILMAN, D.; SOCOLOW, R.; FOLEY, J.A.; HILL, J.; LARSON, E.; LYND, L.; PACALA, S.; REILLY, J.; SEARCHINGER, T.; SOMERVILLE, C.; WILLIAMS, R. (2009) Beneficial Biofuels—The Food, Energy, and Environment Trilemma. *Science*. 325(5938), 4–5.

TODD, S.W.; HOFFER, R.M.; MILCHUNAS, D.G. (1998) Biomass estimation on grazed and ungrazed rangelands using spectral indices. *International Journal of Remote Sensing*. 19(3), 427–438.

TRILLA, G.G.; DE MARCO, S.; MARCOVECCHIO, J.; VICARI, R.; KANDUS, P. (2010) Net primary productivity of *Spartina densiflora* brong in an SW Atlantic Coastal salt marsh. *Estuaries and Coasts*. 33(4), 953–962.

VERÓN, S.R.; JOBBÁGY, E.G.; DI BELLA, C.M.; PARUELO, J.M.; JACKSON, R.B. (2012) Assessing the potential of wildfires as a sustainable bioenergy opportunity. *GCB Bioenergy*. 4(6), 634–641.

VILJANEN, N.; HONKAVAARA, E.; NÄSI, R.; HAKALA, T.; NIEMELÄINEN, O.; KAIVOSOJA, J. (2018) A novel machine learning method for estimating biomass of grass swards using a photogrammetric canopy height model, images and vegetation indices captured by a drone. *Agriculture (Switzerland)*. 8(5).

VILLOSLADA PECIÑA, M.; BERGAMO, T.F.; WARD, R.D.; JOYCE, C.B.; SEPP, K. (2021) A novel UAV-based approach for biomass prediction and grassland structure assessment in coastal meadows. *Ecological Indicators*. 122, 107227.

WANG, S ming; CUI, G. qing; WANG, H.; MA, F. ying; XIA, S. sai; LI, Y. feng; YANG, Z. lin; LING, Y. hua; ZHANG, C. wei; HE, G. hua; ZHAO, F. ming (2019) Identification and QTL mapping of Z550, a rice backcrossed inbred line with increased grains per panicle. *Journal of Integrative Agriculture*. 18(3), 526–531.

YANG, X.; GUO, X. (2014) Quantifying Responses of Spectral Vegetation Indices to Dead Materials in Mixed Grasslands. *Remote Sensing*. 6(5), 4289–4304.

ZENG, N.; REN, X.; HE, H.; ZHANG, L.; ZHAO, D.; GE, R.; LI, P.; NIU, Z. (2019) Estimating grassland aboveground biomass on the Tibetan Plateau using a random forest algorithm. *Ecological Indicators*. 102, 479–487.

JOZAMI, E.; DI LEO, N.; BARBONA, I.; FELDMAN, S. Modelos predictivos para la estimación de biomasa de *Spartina argentinensis*. *Ciencias Agronómicas*, (45), e047. <https://doi.org/10.35305/agro45.e047>

Copyright (c) 2025 E.Jozami, N.Di Leo, I.Barbona, S.R.Feldman



Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial-CompartirIgual 4.0](https://creativecommons.org/licenses/by-nc-sa/4.0/).