

Identificación, mapeo y estimación de biomasa de los pastizales en la región ganadera de Argentina utilizando imágenes ópticas y SAR

Por ***Jonatan Javier Mogadouro***

Presentado ante la Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich como parte de los requerimientos para la obtención del grado de

MAGISTER EN APLICACIONES DE INFORMACIÓN ESPACIAL

UNIVERSIDAD NACIONAL DE CÓRDOBA

07, 2022

©IG-CONAE 2022
©FaMAF-UNC 2022

DIRECTOR

M.Sc. Ignacio Gastón Pascual

Instituto Gulich, Córdoba, Argentina



Esta obra está bajo la licencia:

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Agradecimientos

Al recorrer este sendero de investigación quiero agradecer a aquellas personas que estuvieron siempre dispuestas a escucharme, aconsejarme, alentarme y darme ese empujón cuando fue necesario. En primer lugar deseo agradecer a las dos personitas que me dieron la vida Victor y Noemi por sus esfuerzos para brindarme siempre una buena educación y prepararme para los tiempos futuros, por enseñarme buenos principios, tanto en la vida como en la educación para lograr ser la persona que soy. A mis hijos Antonio y Justina por aparecer en mi vida y enseñarme que el amor no tiene límites. A mi novia Dani por su apoyo incondicional y por aguantarme en esta etapa tan demandante de mi vida. A mi hermana Vicky por ser mi fiel compañera de la vida y demostrarme que con esfuerzo y perseverancia se encuentra el éxito. A mi abuela Nelly por seguir estando a mi lado y enseñarme a ver la vida con optimismo. Al resto de mi familia (primos, tíos, suegros y cuñados), gracias por ser aún mejor que la que pude alguna vez haber soñado. Agradecer a los amigos que siempre están en los buenos y malos momentos. A mi director de tesis Ignacio Pascual por su apoyo, paciencia y dedicación para llevar esta tesis a su forma final. Agradecer a la Empresa VENG S.A en la cual trabajo, y a mis superiores Álvaro Soldano y Laura Frulla por apoyarme y brindarme esta gran oportunidad para especializarme en el procesamiento de imágenes satelitales. Agradezco al Instituto Gulich de la CONAE por proporcionarme el espacio y una excelente calidad académica, como así también, a los profesores del cursado por la calidez de enseñanza. A Claudia Notarnicola por compartirme desinteresadamente sus conocimientos y al Instituto EURAC por la estadía de investigación en Bolzano, Italia. Dar las gracias al equipo EMIS por la buena onda, compañerismo y por compartir junto a ellos un ambiente laboral agradable. Muchas gracias al Ingeniero Agrónomo Martín Durante (investigador de la EEA INTA Concepción del Uruguay) y Mattia Rossi (investigador del Instituto EURAC Research) por haberme brindarme la información de campo imprescindible para la construcción de este trabajo de investigación. A mis compañeros de pasantía en Italia (Santi y Pauli) agradecerles por acompañarme, ayudarme y compartir esta bella experiencia juntos. Finalmente, les regalo un fuerte aplauso a mis compañeros de la MAIE, quienes hicieron que el cursado de esta maestría sea un poco mas liviana compartiendo alegrías, miedos, conocimientos y ayudándonos mutuamente a lo largo de estos dos años. Auguri!

Resumen

Los pastizales cubren aproximadamente el 40 % de la superficie terrestre mundial y más del 70 % del territorio nacional argentino, siendo el sustento principal de los sistemas ganaderos. Se reconocen tres tipos principales de pastizales que se pueden distinguir dentro de un sistema productivo según su manejo: pastizales naturales (objeto de estudio de este trabajo de investigación), semi-naturales, y praderas mejoradas. En este contexto, la planificación de manejo del pastoreo sobre estas cubiertas vegetales está enfocada principalmente en el control de la carga animal, los periodos de utilización y descanso de los potreros, suplementación, entre los más importantes para una gestión eficiente dentro de un sistema productivo sustentable. Por ello, se genera la necesidad en lograr determinar la cantidad de forraje producido por los pastizales sumado a la disponibilidad del personal necesaria para las mediciones de biomasa vegetal efectuadas a campo.

En este sentido la información que aportan las imágenes satelitales han demostrado su gran utilidad para la estimación de biomasa vegetal, clasificación de pasturas, como así también, para el monitoreo de distintas coberturas vegetales a distintas escalas.

Como primera instancia para este trabajo de investigación, se plantearon las bases teóricas para la estimación de biomasa disponible de los pastizales naturales mediante el uso de imágenes SAR (S-1) y ópticas (S-2 y L-8) para una zona de estudio principal localizada en la región centro-sur de Entre Ríos (Argentina), en comparación a un área de estudio secundaria ubicada en la región de Val Mazia (norte de Italia). Se analizó el comportamiento de las distintas variables obtenidas a partir de los datos ópticos y de radar para determinar su posible correlación con las muestras *in situ* de biomasa de los pastizales naturales (MIBIOP) con el objeto de modelar la producción de biomasa (computados por medio del software estadístico R).

Para los sitios de estudio de Entre Ríos las variables que mejor respuesta obtuvieron para interpretar la biomasa a través del análisis de Regresión Lineal Simple (SLR) fueron: la retrodispersión en la polarización VH y Ratio VH/VV (datos SAR), sumado a los valores del índice NDVI (provenientes de la sinergia entre los datos de S-2 y L-8). Cabe aclarar que, no se encontró respuesta alguna en la polarización VV.

De manera análoga, se replicó dicho procedimiento en la zona de Val Mazia escogiendo las variables estimativas más representativas, seleccionando los valores de retrodispersión en la polarización VH y VV (datos SAR), sumado a los valores del índice NDVI (provenientes de la combinación entre los datos de S-2 y L-8). En esta área de estudio no se cuantificó correlación para la variable Ratio VH/VV.

Los resultados logrados aplicando un modelo de SLR demuestran que el σ^0 en la polarización VH manifestó la mejor respuesta estimativa de biomasa en relación a las MIBIOP para las series temporales analizadas, tanto en los sitios de estudio en Entre Ríos, como en área analizada en la región de Val Mazia.

Seguidamente, se usaron dichas variables para realizar un análisis sinérgico a través de un modelo de Regresión Lineal Múltiple (MLR), que integró la información derivada de datos ópticos y SAR. Los resultados obtenidos a partir de la complementación de datos lograron mejorar la precisión del modelo predictivo de biomasa de los pastizales tanto en los sitios de estudio de Entre Ríos como en el área de Val Mazia.

A partir de los coeficientes de regresión generados con las variables usadas en el modelo MLR (ecuación ajustada de la recta de mínimos cuadrados) se confeccionó de un mapa de visualización de biomasa estimada de pastizales en una de las zonas de estudio de Entre Ríos ('sitio 1' y su entorno). El resultado del modelo (y el consecuente mapa) podría ser utilizado para el cálculo de carga animal, en función de la disponibilidad de materia seca en el tiempo.

Para lograr determinar si existe una relación no lineal entre las variables provenientes de datos ópticos y SAR para la biomasa estimada de los pastizales, se sugiere el uso de algún modelo de aprendizaje automático (redes neuronales) que incorpore funciones no lineales en el análisis estadístico, como así también, una mayor disponibilidad de datos *in situ* de biomasa de los pastizales para lograr mejorar la precisión de los modelos estimativos.

En la segunda parte de este trabajo de investigación se describe la experiencia de clasificación de pastizales en la región centro-norte de Entre Ríos, Argentina, con el objeto de identificar y mapear pastizales en una zona de estudio definida, mediante el uso de clasificadores supervisados (Mahalanobis Distance) y no supervisados (K-Means) aplicadas sobre un conjunto de imágenes de radar (S-1) y ópticas (S-2). La información obtenida a partir de los clasificadores se utiliza para poder describir el territorio, sus características fisiográficas y los usos del suelo que predominan, información que de otra manera sería muy difícil de recabar.

Para determinar la precisión de los clasificadores, se procedió al cómputo de matrices de confusión analizando la precisión global y el índice Kappa que arroja cada algoritmo.

Se obtuvo una respuesta positiva por parte de los algoritmos seleccionados, logrando una precisión de clasificación con más del 85 % de precisión global y un índice Kappa superior a 0.79, donde los resultados destacan al algoritmo Mahalanobis Distance como el más preciso en relación a K-Means generados en función de datos SAR y ópticos.

En la post-clasificación se realizó una confrontación entre los mapas clasificados en relación a un producto validado 'Land Cover Classification' para la diferenciación de coberturas vegetales, como así también, se evaluó a modo puntual la proporción de aciertos a partir de la clase computada como 'Pastizales' determinada por cada clasificador, contrastada con la verdad a campo a partir de 13 sitios distribuidos alrededor de la zona de estudio (datos *in situ* de pastizales) para una validación puntual de resultados.

A partir de la evaluación y comparación de los métodos de clasificación aquí presentados se recomienda el uso del algoritmo de Mahalanobis Distance en función de datos SAR (S-1) el cual logra muy buenos resultados en la discriminación de distintos tipos de coberturas vegetales.

Palabras clave: Biomasa - Pastizales – Datos Ópticos – Datos SAR - Clasificación

Abstract

Grasslands cover approximately 40% of the global land area and more than 70% of Argentina's national territory, being the main sustenance for livestock systems. Three main types of grasslands can be distinguished within a productive system according to their management: natural grasslands (the study object of this research work), semi-natural grasslands, and improved grasslands. In this context, the planning of grazing management on these vegetation covers is mainly focused on the control of stocking rates, the periods of use and rest of the paddocks, supplementation, among the most important for an efficient management within a sustainable production system. Therefore, there is a need to determine the amount of forage produced by the pastures and the availability of the necessary personnel to measure vegetation biomass in the field.

In this sense, the information provided by satellite images has proven to be very useful for estimating vegetation biomass, grassland classification, as well as for monitoring different vegetation covers at different scales.

As a first instance for this research work, the theoretical basis for the available biomass estimation of natural grasslands using SAR (S-1) and optical (S-2 and L-8) images was proposed for a main study area located in the south-central region of Entre Ríos (Argentina), compared to a secondary study area located in the Val Mazia region (northern Italy). The behaviour of the different variables obtained from the optical and radar data was analysed to determine their possible correlation with in situ biomass samples of natural grasslands (MIBIOP) in order to model biomass production (computed using R statistical software). For the study sites in Entre Ríos, the variables that obtained the best response to interpret biomass through Simple Linear Regression analysis were: the backscatter in VH polarization and VH/VV Ratio (SAR data), together with the NDVI index values (coming from the synergy between S-2 and L-8 data). It should be noted that no response was found in the VV polarization.

For the Entre Ríos study sites, the variables that provided the best response for interpreting biomass through Simple Linear Regression (SLR) analysis were: backscatter in VH polarization and VH/VV Ratio (SAR data), in addition to, the NDVI index values (resulting from the synergy between S-2 and L-8 data). It should be noted that no response was found for VV polarization.

In a similar way, this procedure was replicated in the Val Mazia area, choosing the most representative estimating variables, selecting the backscatter values in the VH and VV polarization (SAR data), in addition to the NDVI index values (obtained from the synergy between the S-2 and L-8 data). In this study area no correlation was quantified for the variable VH/VV Ratio.

The results achieved by applying a SLR model demonstrated that the σ^0 in the VH polarisation showed the best biomass estimation response in relation to the MIBIOP for the time series analysed, for the study sites in Entre Rios, as well as in the area analysed in the Val

Mazia region.

These variables were then used to perform a synergistic analysis through a Multiple Linear Regression (MLR) model, which integrated information derived from optical and SAR data. The results obtained from the data complementation improved the accuracy of the predictive model of grassland biomass in both the Entre Ríos study sites and in the Val Mazia area.

From the regression coefficients generated with the variables used in the MLR model (fitted equation of the least squares line) a visualization map of estimated grassland biomass in one of the Entre Rios study areas ('site 1' and its surroundings) was produced. The model output (and the consequent map) could be used to calculate stocking rates, based on dry matter availability over time.

In order to determine whether there is a non-linear relationship between variables from optical and SAR data for estimated grassland biomass, the use of a machine learning model (neural networks) that incorporates non-linear functions in the statistical analysis is suggested, as well as greater availability in situ data of grassland biomass to improve the estimation models accuracy.

The second part of this research work describes the experience of grassland classification in the north-central region of Entre Ríos, Argentina, with the aim of identifying and mapping grasslands in a defined study area, using supervised (Mahalanobis Distance) and unsupervised (K-Means) classifiers applied on a set of radar (S-1) and optical (S-2) images. The information obtained from the classifiers is used to describe the territory, its physiographic characteristics and the predominant land uses, information that would otherwise be very difficult to gather.

To determine the accuracy of the classifiers, confusion matrices were computed, analysing the overall accuracy and Kappa index of each algorithm.

A positive response was obtained from the selected algorithms, achieving a classification accuracy of more than 85% overall accuracy and a Kappa index of more than 0.79, where the results highlight the Mahalanobis Distance algorithm as the most accurate in relation to K-Means generated based on SAR and optical data.

In the post-classification, a confrontation was made between the classified maps in relation to a validated product 'Land Cover Classification' for the differentiation of vegetation cover, as well as a punctual evaluation of the proportion of hits from the class computed as 'Grasslands' determined by each classifier, contrasted with the ground truth from 13 sites distributed around the study area (in situ data of grasslands) for a punctual validation of results.

From the evaluation and comparison of the classification methods presented here it recommends the use of the Mahalanobis Distance algorithm based on SAR data (S-1) which achieves very good results in discriminating different types of vegetation cover.

Keywords: Biomass - Grasslands - Optical data - SAR data -Classification

Índice de Contenidos

1. Introducción	1
1.1. Objetivos	4
1.1.1. General	4
1.1.2. Específicos	4
2. Marco Teórico	5
2.1. Antecedentes	5
2.2. Teledetección	8
2.3. Radar de Apertura Sintética	12
2.3.1. Definición, concepto de funcionamiento y geometría de adquisición de un SAR	12
2.3.2. Interacción de la radiación electromagnética con la materia	16
3. Área de estudio	18
3.1. Sitio experimental	18
3.1.1. Región de Entre Ríos (Argentina)	18
3.1.1.1. Fitogeografía	18
3.1.1.2. Clima	19
3.1.1.3. Características edáficas	20
3.1.2. Región de Val Mazia (Italia)	20
3.1.2.1. Clima	21
3.1.2.2. Fitogeografía	22
4. Materiales y Métodos	23
4.1. Adquisición de imágenes satelitales	23

4.1.1.	Imágenes Sentinel-1	23
4.1.2.	Imágenes Sentinel-2	24
4.1.3.	Imágenes Landsat-8	25
4.2.	Datos de campo	26
4.2.1.	Región de Entre Ríos, Argentina	26
4.2.2.	Región de Val Mazia, Italia	29
4.3.	Pre-procesamiento de imágenes satelitales	30
4.3.1.	Pre-procesamiento de imágenes Sentinel-1	30
4.3.2.	Pre-procesamiento de imágenes Sentinel-2	33
4.3.3.	Pre-procesamiento de imágenes Landsat-8	34
4.4.	Procesamiento de imágenes satelitales	34
4.4.1.	Procesamiento de imágenes ópticas (Sentinel-2 y Landsat-8)	34
4.4.2.	Procesamiento de imágenes de radar (Sentinel-1)	36
4.5.	Análisis de datos y variables disponibles que intervienen en el proceso de estimación de biomasa de los pastizales	37
4.5.1.	Evaluación de la información óptica	39
4.5.1.1.	Comparación de diferentes índices de vegetación	39
4.5.1.2.	Relación entre la biomasa de los pastizales y el índice NDVI	41
4.5.2.	Evaluación de la información SAR	42
4.5.2.1.	Evolución de biomasa de los pastizales en relación a la retrodispersión (S-1)	42
4.5.2.2.	Análisis de precipitaciones en función a la retrodispersión SAR	48
4.6.	Aplicación de un modelo de Regresión Lineal Múltiple para la estimación de biomasa de los pastizales	50
4.7.	Generación del mapa de biomasa de los pastizales estimado a partir del modelo MLR	53
4.8.	Identificación y mapeo de áreas con pastizales en la región centro-norte de Entre Ríos utilizando imágenes ópticas y de radar	54
4.8.1.	Clasificación con imágenes ópticas (S-2)	55
4.8.2.	Clasificación con imágenes de radar (S-1)	59

4.8.3. Desempeño de los algoritmos de clasificación	61
5. Resultados y discusión	62
5.1. Resultados obtenidos en el proceso estimativo de biomasa de los pastizales mediante información satelital	62
5.1.1. Análisis de la regresión entre la materia seca de los pastizales y los datos ópticos (índice NDVI)	62
5.1.2. Resultados estimativos de biomasa de los pastizales a partir de datos SAR	64
5.2. Evaluación del comportamiento de las variables del modelo MLR para la estimación de biomasa de los pastizales	68
5.3. Mapa estimativo de biomasa de los pastizales	71
5.4. Mapas resultantes según algoritmos de clasificación seleccionados	72
5.4.1. Mapas obtenidos mediante imágenes ópticas	72
5.4.2. Mapas obtenidos mediante imágenes SAR	73
5.4.3. Análisis del desempeño de los algoritmos de clasificación	75
6. Conclusiones	79
Anexos	91
A. Listado de todas las imágenes satelitales utilizadas en el área de estudio: Entre Ríos	92
B. Listado de todas las imágenes ópticas descartadas por presencia de nubes	96
C. Listado de todas las imágenes satelitales utilizadas en el área de estudio: Val Mazia	97
D. Script utilizado para el cálculo de las regresiones y análisis de supuestos de normalidad (Argentina e Italia)	99
E. Supuestos de normalidad e independencia de cada variable usada en el modelo de regresión lineal simple y múltiple	101
F. Gráficos de la correlación entre el índice NDVI y los índices SAVI y GNDVI	

(área de estudio: Entre Ríos)	104
G. Gráficos de distribución de todos los valores de (σ_0) y MIBIOP obtenidos en los sitios de estudio de Entre Ríos	105
H. Gráficos de distribución de todos los valores de (σ_0) y MIBIOP obtenidos en el sitio de estudio de Val Mazia	107
I. Correlación entre los sensores ópticos S-2 y L-8	108
J. Imágenes utilizadas en la identificación y mapeo de áreas con pastizales en la región centro-norte de Entre Ríos	109
K. Matrices de confusión	110
L. Puntos aleatorios obtenidos sobre el área de interés (Centro-norte Entre Ríos) para análisis post-clasificación	112
M. Mapa de clasificación comparativo	113

Índice de figuras

2.1. Sistema de teledetección pasiva (superior) y activa (inferior)	9
2.2. Esquema de una onda electromagnética	9
2.3. El espectro electromagnético y la energía fotónica de la luz visible	10
2.4. Curva de reflectancia típica de la vegetación vigorosa, mostrando los factores dominantes que controlan la reflectancia de la hoja	11
2.5. Ventanas atmosféricas y bandas de absorción	12
2.6. Vista general de la geometría de un SAR	13
2.7. Sensibilidad de las mediciones de SAR a la penetración en el dosel según diferentes longitudes de onda utilizadas	15
2.8. Planos de copolarización de la onda EM	15
2.9. Distorsiones geométricas generadas en una imagen SAR. 1) Acortamiento: a la distancia real a-b le corresponde en la imagen una distancia mucho menor $a'-b'$; 2) Inversión: el segmento de terreno a-b aparece en la imagen invertido $b'-a'$; 3) Sombreado: un segmento del terreno nunca es alcanzado por la señal del radar.	17
3.1. Área de estudio principal para la identificación y mapeo de los pastizales (región centro-norte de Entre Ríos, Argentina) y para la estimación de biomasa de los pastizales (región sur de Entre Ríos, Argentina)	19
3.2. Área de estudio secundaria para la estimación de biomasa de los pastizales: Val Mazia, Italia	21
4.1. Adquisición de imágenes S-1 en modo 'offline' desde el portal de la ESA del área de estudio en Argentina	24
4.2. Adquisición de imágenes L-8 desde el portal USGS del área de estudio en Argentina	25
4.3. Puntos de muestreos a campo (Entre Ríos, Argentina)	26

4.4. Paisaje y vegetación típica en las zonas muestreadas en la región centro-norte de Entre Ríos, Argentina	27
4.5. Paisaje y vegetación típica en las zonas muestreadas en la región centro-sur de Entre Ríos, Argentina	28
4.6. Puntos de muestreos a campo (Val Mazia, Italia)	29
4.7. Distribución de los pastizales en el área muestreada (Val Mazia, Italia) . . .	30
4.8. Esquema de pre-procesamiento de imágenes SAR y ópticas	31
4.9. Imágenes resultantes al aplicar los distintos filtros con SNAP	32
4.10. Esquema de procesamiento de las imágenes SAR y ópticas adquiridas . . .	35
4.11. Ventana de apilamiento y georeferenciación de las imágenes a través de ENVI	36
4.12. Evolución temporal de la biomasa de los pastizales en los sitios de estudio principales (región centro-sur de Entre Ríos, Argentina)	37
4.13. Evolución temporal de la biomasa de los pastizales en el sitio de estudio secundario (región de Val Mazia, Italia)	38
4.14. Evolución temporal de la biomasa de los pastizales con respecto a los índices ópticos NDVI, SAVI y GNDVI para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)	40
4.15. Evolución temporal de la biomasa de los pastizales y el índice NDVI para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)	41
4.16. Evolución temporal de la biomasa de los pastizales y el índice NDVI (región de Val Mazia)	42
4.17. Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b) sin considerar imágenes con eventos de lluvia hasta dos días previos a la adquisición de la misma ('sitio 1', Entre Ríos)	43
4.18. Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b) sin considerar imágenes con eventos de lluvia hasta dos días previos a la adquisición de la misma ('sitio 2', Entre Ríos)	44
4.19. Evolución temporal de la biomasa de los pastizales y los valores calculados y estimados de Ratio VH/VV para el 'sitio 1' (a) y 'sitio 2' (b), Entre Ríos .	46
4.20. Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b), sin considerar imágenes con eventos de lluvias (Val Mazia)	47

4.21. Evolución temporal de la biomasa de los pastizales y los valores calculados y estimados de Ratio VH/VV (Val Mazia)	48
4.22. Ocurrencia de lluvias y evolución temporal de la biomasa de los pastizales en las áreas de interés ('sitio 1' y 'sitio 2', Entre Ríos)	48
4.23. Respuesta del coeficiente de retrodispersión (polarización VV y VH) en relación a eventos de lluvia ocurridos en el 'sitio 1' (a) y 'sitio 2' (b) (Entre Ríos)	49
4.24. Mapa de áreas destinadas a la producción de arroz (2008/2009) y las represas-lagunas que abastecen a las mismas (Departamento de Feliciano, Entre Ríos)	56
4.25. Capturas de Google 'Street View', correspondientes a diferentes coberturas identificadas en la zona de estudio (región centro-norte de Entre Ríos) . . .	56
4.26. Visualización de las ROIs obtenidas en diferentes coberturas y la máscara de áreas indeseadas realizada sobre una imagen S-2 (región centro-norte de Entre Ríos)	57
4.27. Resultado de la separabilidad espectral de las ROIs realizadas sobre el dataset de imágenes de NDVI (S-2) obtenidas a través de ENVI	58
4.28. Resultado de la separabilidad espectral de las ROIs realizadas sobre el dataset de imágenes con polarización VH (S-1) obtenidas a partir de ENVI . . .	60
5.1. Relación entre la biomasa de los pastizales y los valores de NDVI obtenidos a partir de la sinergia entre las imágenes S-2 y L-8 para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)	63
5.2. Relación entre la biomasa de los pastizales y los valores de NDVI extraídos desde los sensores S-2 y L-8 (región Val Mazia)	64
5.3. Relación entre la biomasa de los pastizales y los valores de retrodispersión en la polarización VH extraídos desde el sensor S-1 para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)	65
5.4. Relación entre biomasa de los pastizales y los valores de ratio VH/VV para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)	66
5.5. Relación entre la biomasa de los pastizales y los valores de retrodispersión en la polarización VH (a) y VV (b) (región de Val Mazia)	66
5.6. Relación entre la biomasa <i>in situ</i> de los pastizales y la biomasa estimada a través del modelo MLR para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos) . .	69
5.7. Relación entre la biomasa <i>in situ</i> de los pastizales y la biomasa estimada a través del modelo MLR (región de Val Mazia)	70

5.8. Mapa estimativo de biomasa de los pastizales a través del modelo MLR (sureste de Entre Ríos)	71
5.9. Clasificación supervisada Mahalanobis Distance (S-2), en la región centro-norte de Entre Ríos	72
5.10. Clasificación no supervisada K-Means (S-2), en la región centro-norte de Entre Ríos	73
5.11. Clasificación supervisada Mahalanobis Distance (S-1), en la región centro-norte de Entre Ríos	74
5.12. Clasificación no supervisada K-Means (S-1), en la región centro-norte de Entre Ríos	74
5.13. Precisión global e índice Kappa obtenidos en los clasificadores evaluados en la región centro-norte de Entre Ríos	75
5.14. Validación entre las áreas clasificadas como pastizales y la verdad de campo en la región centro-norte de Entre Ríos	76
5.15. Visualización de diferentes estratos de vegetación considerados en la clasificación	77
E.1. Homogeneidad de varianza de los errores 'Sitio 1', (Entre Ríos, Argentina)	102
E.2. Homogeneidad de varianza de los errores 'Sitio 2', (Entre Ríos, Argentina)	103
E.3. Homogeneidad de varianza de los errores (Val Mazia, Italia)	103
F.1. Relación entre los valores del índice NDVI con respecto a los valores correspondientes * de los índices SAVI y GNDVI obtenidos de las imágenes S-2 ('sitio 1' y 'sitio 2')	104
G.1. Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en la polarización VH (a) y VV (b) para el 'sitio 1' y en la polarización VH (c) y VV (d) para el 'sitio 2' (Entre Ríos)	106
H.1. Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en la polarización VH (a) y VV (b), Val Mazia	107
I.1. Correlación entre los valores de NDVI obtenidos a partir de los sensores S-2 y L-8 en el área de estudio 'sitio 1'	108
I.2. Correlación entre los valores de NDVI obtenidos a partir de los sensores S-2 y L-8 en el área de estudio 'sitio 2'	108

Índice de tablas

2.1. Bandas, longitudes de onda y frecuencias del EMM (microondas)	14
4.1. Valores de media, desviación estándar y ENL según filtro de speckle utilizado	32
4.2. Datos usados como entrada para la estimación del Ratio VH/VV en aquellas fechas de MIBIOP sin disponibilidad de datos para el 'sitio 1', Entre Ríos (Función: Linear Interpolation)	45
4.3. Datos usados como entrada para la estimación del Ratio VH/VV en aquellas fechas de MIBIOP sin disponibilidad de datos para el 'sitio 2', Entre Ríos (Función: Linear Interpolation)	45
4.4. Datos utilizados como entrada en el modelo MLR para el 'sitio 1' (Entre Ríos, Argentina)	51
4.5. Datos utilizados como entrada en el modelo MLR para el 'sitio 2' (Entre Ríos, Argentina)	52
4.6. Datos utilizados como entrada en el modelo MLR (región de Val Mazia, Italia)	52
5.1. Distribución de las coberturas (en porcentaje) para cada clasificador analizado en la región centro-norte de Entre Ríos	76
5.2. Porcentajes de precisión del usuario y productor en la clase 'Pastizales' . .	78
A.1. Descripción de las imágenes S-1 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina	92
A.2. Descripción de las imágenes S-2 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina	94
A.3. Descripción de las imágenes L-8 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina	95
B.1. Descripción de las imágenes S-2 correspondientes al área de estudio de la región centro-sur de Entre Ríos (Argentina) descartadas por presencia de nubes	96

B.2.	Descripción de las imágenes L-8 correspondientes al área de estudio de la región centro-sur de Entre Ríos (Argentina) descartadas por presencia de nubes	96
C.1.	Descripción de las imágenes S-1 utilizadas en el área de estudio de la región de Val Mazia, Italia	97
C.2.	Descripción de las imágenes S-2 utilizadas en el área de estudio de la región de Val Mazia, Italia	98
C.3.	Descripción de las imágenes L-8 utilizadas en el área de estudio de la región de Val Mazia, Italia	98
E.1.	Estadísticos de salida del Test de Shapiro-Wilks realizado con todas las variables utilizadas en los modelos SLR y MLR a partir del software R	101
J.1.	Imágenes S-2 utilizadas para la clasificación (región centro-norte de Entre Ríos, Argentina)	109
J.2.	Imágenes S-1 utilizadas para la clasificación (región centro-norte de Entre Ríos, Argentina)	109
K.1.	Matrices de confusión calculadas para cada modelo de clasificación evaluado en la región centro-norte de Entre Ríos	110
L.1.	Puntos aleatorios de validación obtenidos con QGIS sobre la región centro-norte de Entre Ríos	112
M.1.	Mapa de clasificación obtenida por la plataforma Copernicus Global Land Service para la región centro-norte de Entre Ríos	113

Acrónimos

AGB Above-Ground Biomass

ANFIS Aptive Neuro Fuzzy Inference Systems Model

ANN Artificial Neural Network

ClaNoSup Clasificación no supervisada

ClaSup Clasificación supervisada

DEM Digital Elevation Model

DSSAT Decision Support System for Agrotechnology Transfer

eV electronvolt

EMM Espectro Electromagnético

ENL Equivalent Number of Looks

EM Electromagnético

ESA European Space Agency

EVI Enhanced Vegetation Index

FAO Organización de las Naciones Unidas para la Alimentación y la Agricultura

GNDVI Green Normalized Difference Vegetation Index

GRD Ground Range Detected

IAF Índice de Área Foliar

IV Índices de Vegetación

IW Interferometric Wide swath

J Joule

L-8 Landsat 8

MIBIOP Muestras in situ de biomasa de los pastizales

MIR Middle-Infrared

MLR Multiple Linear Regression

MS Materia Seca

MTCI Merris Terrestrial Chlorophyll Index

NBDI Normalized Biomass Development Index

NDVI Normalized Differential Vegetation Index

NIR Near-Infrared

PCA Principal Component Analysis

PP Precisión del Productor

PU Precisión del Usuario

REIP Red-Edge Inflection Point

RMSE Root-Mean-Square Error

RVI Radar Vegetation Index

SAFE Standard Archive Format for Europe

SAR Synthetic Aperture Radar

SAOCOM Satélite Argentino de Observación Con Microondas

SAVI Soil Adjusted Vegetation Index

SLR Simple Linear Regression

SR Surface Reflectance

SVM Support Vector Machine

S-1 Sentinel 1

S-2 Sentinel 2

TOA Top of Atmosphere reflectance

TSAVI Transformed Soil Adjusted Vegetation Index

UAVSAR Uninhabited Aerial Vehicle Synthetic Aperture Radar

USGS United States Geological Survey

WCM Water Cloud Model

WOFOST WOrld FOod STudies

σ^0 Coeficiente de Retrodispersión

Capítulo 1

Introducción

Los pastizales entendidos como una comunidad vegetal compleja, predominan extensamente sobre la superficie global cubriendo aproximadamente el 40 % de ella [1],[2],[3]. Según la FAO, contribuyen a los medios de vida de más de 800 millones de personas [4]. Los pastizales ofrecen una gama amplia de servicios ecosistémicos, siendo fuentes de alimentos, fibras y combustibles. Favorecen el control de la erosión y su presencia disminuye los procesos de desertificación de los suelos, como así también, son la fuente de un nutrido banco de semillas que permite la conservación de recurso genético para una cantidad de especies que constituyen la base de la alimentación mundial [5]. Dichas poblaciones vegetales contribuyen tanto directa como indirectamente al cambio climático mediante el secuestro y retención del carbono como así también a la emisión de gases a la atmósfera [6].

Se reconocen tres tipos principales de pastizales que se pueden distinguir dentro de un sistema productivo según su manejo: pastizales naturales, semi-naturales, y praderas mejoradas. Los primeros están conformados por un mosaico de distintas comunidades vegetales dominadas por gramíneas (pastizales serranos) o aquellos en los que coexisten especies leñosas (árboles y arbustos) con hierbas o gramínoideas, como en los biomas de bosques, montes y espinal. Éstas áreas naturales son la fuente de alimento de herbívoros salvajes, pero también son utilizados por el ganado [7], centrando en éstas coberturas el objeto de estudio de este trabajo de investigación.

Los pastizales semi-naturales son aquellos gestionados por el hombre quien modifica los ambientes de paisajes naturales (por ejemplo, bosques) en pastizales o potreros de pastizales. El objetivo es maximizar la producción mediante el pastoreo intensivo y la integración de distintos métodos de aprovechamiento del forraje disponible a través del corte y ensilaje para la alimentación invernal del ganado.

Las praderas mejoradas son aquellas caracterizadas por un manejo intensivo de áreas a las que se les realizaron un conjunto de prácticas culturales (arado, cincelado) que concluyen en la siembra de especies mejoradas de pasturas, en sistemas de producción que incluyen rotación de cultivos, fertilización y riego de las parcelas, con el objeto de alimentar un gran número de animales confinados en potreros con alto potencial de producción [8].

Los ambientes en donde se establecen y desarrollan los pastizales de Sudamérica son recursos productivos claves en la economía de muchos países [5], sin embargo, por efecto de las variaciones climáticas, actividades humanas, sobrepastoreo (consecuente de una mala gestión de manejo de los recursos), se van ocasionando cambios en el paisaje con la consecuente pérdida de productividad de estos ecosistemas [9], [10], [11]. En Argentina los ecosistemas de pastizales ocupan alrededor del 70 % del territorio nacional aunque su extensión ha disminuido debido al avance agrícola [12]. En la Región Pampeana, los remanentes de pastizales naturales quedan relegados a zonas marginadas por condiciones topográficas y ambienta-

les, que afectarían de otra manera negativamente el margen bruto de la producción agrícola preponderante en esta región.

Debido al comportamiento estacional y temporal de estos ecosistemas naturales, resulta de suma importancia en los establecimientos ganaderos lograr la integración de un abanico de conocimientos y factores, para abordar dicha complejidad y maximizar el aprovechamiento de los recursos disponibles para la generación de materia seca [5].

Una adecuada cuantificación de la biomasa producida por los pastizales, es de vital importancia para facilitar la logística en la dinámica de pastoreo del sistema productivo. A partir de dicha información se podrían tomar decisiones de manejo sobre la hacienda: decidir la cantidad de animales a tener en un establecimiento, asignar animales a los diferentes potreros, suplementar, y con ello, mejorar los índices productivos (mantener elevados índices de preñez y una alta concentración de partos al principio del período de pariciones) [13].

Por ello, los sistemas de cría que se sustentan fundamentalmente sobre pastizales naturales persiguen el objetivo de obtener un ternero por vaca por año. El manejo reproductivo deber ser tal que el intervalo entre partos sea de alrededor de 365 días, pero en gran parte de los rodeos de cría de Argentina el promedio de destete anual ronda el 62% desde hace varios años [14].

La realidad del sector productivo del país se asocia a practicas informales de sistematización de la información (boca en boca, anotaciones imprecisas, etc.), determinando en una baja disponibilidad de datos de producción forrajera, de manera paralela el alto costo operativo de las mediciones necesarias para obtener dicha información refuerzan la escasez de datos.

Existen diferentes metodologías para cuantificar la biomasa producida, en términos generales podemos diferenciar dos grandes grupos, los métodos destructivos y los métodos no destructivos. Ambos son lentos y los costos laborales asociados con el estudio de las extensas y a menudo inaccesibles áreas de pastizales resultan muy dificultoso. Además, los primeros no permiten repeticiones en la misma área por su carácter destructivo. En cuanto a los métodos no destructivos, la complejidad se encuentra ligada al costo de los instrumentos de medición (como por ejemplo el pasturómetro de altura). Esto lleva tanto a los investigadores como a los productores, a buscar métodos indirectos para la estimación de la biomasa, que sean repetibles y que permitan la monitorización de la vegetación a gran escala y bajo costo [6], [15].

En este contexto, la teledetección podría ocupar el lugar del primer eslabón para la generación de metodologías de estimación de biomasa de manera indirecta a través del flujo de información energética que es emitida o reflejada por la superficie terrestre y captada por el sensor. De acuerdo al tipo, composición, altura y densidad de la vegetación, será la proporción y el tipo de radiación electromagnética que se refleje.

A partir de esa información se pueden construir modelos simples por medio de índices multiespectrales generados con datos ópticos o álgebra de bandas con información SAR, los cuales miden diferentes propiedades de los objetos presentes en la superficie terrestre, para correlacionarlos con la producción de biomasa en los pastizales naturales. Un índice muy estudiado en la agricultura llamado NDVI (por sus siglas en inglés Normalized Differential Vegetation Index) permite estimar la cantidad, calidad y desarrollo de la vegetación por medio de sensores remotos ópticos [5], como así también el índice RVI (por sus siglas en inglés Radar Vegetation Index) obtenido mediante imágenes full polarimétricas de radar como las generadas por los sensores SAOCOM [16]. En el caso de los sensores SAR con polarización dual como Sentinel-1, permiten el cálculo del Ratio VH/VV combinando la señal

de retrodispersión en los canales co-polarizados y con polarización cruzada para el estudio de la fenología de las especies vegetales [17]. Estos índices guardan una relación estrecha con la actividad fotosintética, con la alometría de los vegetales que podrían correlacionarse con la biomasa y por lo tanto, de alguna manera con la tasa de crecimiento de la vegetación, donde el NDVI es más sensible a los componentes químicos foliares y en el caso de los instrumentos SAR, la señal de retrodispersión es más sensible a las formas o estructuras de la vegetación (suma total de hojas, ramas y tallos) y afectada por la humedad del suelo, la rugosidad de la superficie y la topografía del terreno [18]. Dicha tasa de crecimiento o productividad forrajera, se puede expresar de dos formas diferentes, como radiación fotosintéticamente activa absorbida por la vegetación o como kilos de alimento/biomasa producido por unidad de superficie en un tiempo dado [19].

Por otro lado, para lograr monitoreos apropiados de los hábitats terrestres, donde los pastizales naturales ocupan una extensión importante, el uso de la teledetección se hace cada vez más fuerte. Debido a biodiversidad tanto espacial, estructural como temporal de las especies vegetales que componen los ecosistemas de pastizales, su mapeo, se considera aún en la actualidad como un gran desafío de los científicos e investigadores [18].

En el marco de este trabajo de investigación, se utilizará información óptica y SAR, para identificar y mapear las zonas de interés con pastizales naturales, empleando técnicas de clasificación, donde la información categorizada obtenida se utilizará posteriormente para generar mapas temáticos. Dichas técnicas de clasificación empleadas fueron: Mahalanobis Distance (clasificación supervisada) y K-Means (clasificación no supervisada). Donde los primeros se validan a partir de datos de referencia *in situ*, lo cual, exige un mayor costo computacional y recurso humano, dificultando su extrapolación temporal o para el análisis en otros sitios de interés [20]. El método no supervisado por el contrario, no requiere conocimiento previo del usuario sobre el área bajo investigación y cuyo procesamiento posee bajo costo computacional. Sin embargo, generalmente poseen menos precisión en comparación a los algoritmos supervisados [21].

Por lo antes mencionado y en función a los objetivos de este trabajo, se considera el uso de la información satelital para la identificación y mapeo de la vegetación herbácea/arbus-tiva nativa que componen los pastizales naturales, como así también, para la estimación de biomasa/alimento disponible para el ganado en un área de interés ubicada en la región centro-este de nuestro país. Dichas fuentes de datos permitiría a los usuarios/productores disponer de una herramienta de soporte extra en la toma de decisiones para el ajuste de variables productivas como la carga animal de la hacienda con la mayor eficiencia posible (control cabezas por unidad de área y la duración de la temporada de pastoreo en los mismos) [15]. Estas herramientas favorecen la gestión del sistema productivo en diferentes escalas, desde el alcance local hasta el regional, colaborando en el progreso de los mismos hacia la sustentabilidad [22], [23], [24], [25].

Resaltando finalmente, la importancia que posee dicho recurso natural en un sistema productivo ganadero constituyendo su principal fuente de recurso forrajero [26]. Asimismo, al integrar la cadena productiva de nuestro país, es una fuente de sustento fundamental en muchas industrias cárnicas, lácteas y laníferas [15].

1.1. Objetivos

1.1.1. General

El objetivo principal de este trabajo es:

Desarrollar una metodología para la identificación y el mapeo de pastizales naturales en una zona circunscripta en el centro-norte de la provincia de Entre Ríos a partir del uso de imágenes ópticas y SAR.

1.1.2. Específicos

- Definir bases teóricas para la estimación de biomasa/alimento disponible de pastizales naturales a través de imágenes ópticas y SAR para determinar la capacidad de carga animal instantánea de un sistema productivo.
- Implementar técnicas de identificación y mapeo de áreas con pastizales naturales en la provincia de Entre Ríos utilizando imágenes ópticas y SAR.
- A partir de la disponibilidad de datos satelitales de diferentes sensores (ópticos y de radar), índices de vegetación, polarizaciones y resoluciones, seleccionar las mejores combinaciones de estos parámetros en relación con los estudios de pastizales naturales identificando sus ventajas y limitaciones.

Capítulo 2

Marco Teórico

2.1. Antecedentes

La estimación de la biomasa producida en una superficie se considera un problema que involucra a toda la cadena de valor de la producción de carne, algunos de los métodos empleados a partir del sensado remoto para la estimación de la misma se detallan a continuación:

- Desarrollo de modelos de regresión como el MLR para la estimación productiva de los pastizales a partir de diferentes Índices de Vegetación obtenidos desde las plataformas satelitales tanto ópticas como de radar.
- Uso de diferentes algoritmos de aprendizaje automático como por ejemplo, ANN (de sus siglas en inglés Artificial Neural Network) y SVM (de sus siglas en inglés Support Vector Machine).
- Modelos que simulan el crecimiento, desarrollo y rendimiento de los cultivos combinando los parámetros derivados de datos satelitales y mediciones terrestres como por ejemplo, DSSAT, WOFOST, Lingra entre otros [15].

Entre los índices de vegetación (IV) ampliamente utilizados en teledetección, encontramos al NDVI como uno de los más estudiados para el seguimiento de las cubiertas vegetales pero su principal limitación se debe a que las bandas espectrales roja y NIR del espectro electromagnético se aproximan asintóticamente a un nivel de saturación después de cierta densidad de biomasa, sumado a las variaciones temporales y espaciales de los valores de NDVI de los pastizales generados a escala local, por lo que los resultados son difíciles de transferir para el análisis a escala regional [3].

Como indican Ullah et al. en [27] un estudio realizado a partir de información óptica del sensor MERIS para la estimación de biomasa de los pastizales en la región norte de los Países Bajos, se usaron distintos índices (NDVI, SAVI, TSAVI, REIP, MTCI) y parámetros del análisis de profundidad de banda (para diferentes longitudes de onda de absorción). Se aplicaron técnicas de regresión lineal simple y múltiple para modelar las relaciones entre las propiedades de la vegetación (biomasa verde, concentración de nitrógeno y densidad de nitrógeno) y las variables nombradas. Los resultados de los modelos de regresión demostraron que el índice SAVI obtuvo un coeficiente de determinación ligeramente mayor ($R^2=0.54$) en comparación con los otros índices para la estimación de biomasa verde. La estimación de la concentración de nitrógeno fue deficiente y la densidad de nitrógeno se predijo con una precisión razonable. Entre los parámetros de análisis de profundidad de la banda seleccionados, el índice NBDI estimó la biomasa verde y la densidad del nitrógeno con mayor precisión

que los IV más convencionales (NDVI, SAVI y TSAVI) con un R^2 ajustado de 0.73 y 0.51 respectivamente.

Así mismo Zhang et al. en [28] emplearon un modelo compuesto de la fusión de datos de NDVI (sintéticas) provenientes de los satélites ópticos Landsat y MODIS y algoritmos de regresión (SVM) para la estimación de biomasa de los pastizales (de sus siglas en inglés AGB) en toda el área de pastizales de Xilinhot, interior de Mongolia, China. Los resultados demuestran que el modelo generado a partir de las imágenes sintéticas puede garantizar la precisión de las estimaciones de AGB ($R^2=0.73$ y $RMSE=30.61$ gr/m²) en comparación con las estimaciones de AGB a partir de los datos MODIS ($R^2=0.77$ y $RMSE=17.22$ gr/m²). Es importante destacar que se mejoró la resolución espacial (30 metros) y temporal (8 días), lo que indica que la integración de los datos sintéticos de NDVI y el modelo SVM puede producir estimaciones precisas de AGB en áreas de pastizales para optimizar el manejo de dichos recursos.

En cuanto a la escala de análisis de pastizales, también se han realizado estudios para la estimación de biomasa (kg MS/ha) a pequeña escala como el trabajo de investigación desarrollado por I. Ali et al. [29] sobre un pequeño campo ganadero de Irlanda. Se usaron cinco índices de vegetación más dos bandas espectrales sin procesar (RED=Red band, NIR=Near Infrared band) derivadas de un producto óptico (MODIS) como datos de entrada para los siguientes modelos predictivos seleccionados: Multiple Linear Regression (MLR), Artificial Neural Network (ANN) y Adaptive Neuro Fuzzy Inference Systems Model (ANFIS). Considerando que para la validación de los modelos se dispuso de muestras a campo de biomasa de las pasturas en dos áreas (Grange y Moorepark), con una ventana temporal de 6 años (2001-2005 y 2007) y 12 años (2001-2012) respectivamente. Además, se realizó un análisis de componentes principales (de sus siglas en inglés PCA) para reducir la dimensionalidad de los datos y la dependencia de las variables. Los resultados demuestran que para estimar la biomasa de los pastizales con el modelo MLR, se obtuvo una regresión lineal sólida entre el conjunto de datos estimados y los valores a campo. A pesar de ello en el área Moorepark el valor del coeficiente de determinación para MLR es muy bajo ($R^2=0.29$) y el valor de $RMSE=25.08$, es alto en comparación con el modelo ANN ($R^2=0.63$, $RMSE = 18.05$), sugiriendo una relación no lineal entre las variables. Siguiendo la misma tendencia en los resultados del otro sitio muestreado (Grange) se obtuvo para el modelo ANN un $R^2=0.59$ y $RMSE=20.43$ y para MLR un $R^2=0.38$ y $RMSE=24.02$. En cuanto a los resultados del modelo de ANFIS, éste obtuvo mejores resultados de estimación de la biomasa en comparación con el ANN y MLR obteniendo en Moorepark un $R^2=0.85$, $RMSE=11.07$ y en Grange $R^2=0.76$, $RMSE=15.35$. Hasta la fecha, el uso de algoritmos de aprendizaje automático para la estimación de biomasa de pastizales no está muy extendido. Dos estudios realizados sobre zonas con pastizales en China con detección remota óptica [30],[31] compararon el rendimiento de MLR y ANN, y en todos los casos, ANN superó a MLR.

En un reciente trabajo Reisi-Gahroue et al. [32], evaluaron y desarrollaron modelos de MLR y ANN para estimar la biomasa de los cultivos de canola, maíz y soja a partir de datos SAR polarimétricos multitemporales de banda L (UAVSAR) cuyos resultados demostraron que ANN proporcionó estimaciones de biomasa más precisas en comparación con MLR. Estas redes neuronales utilizan funciones no lineales en su modelo haciendo uso de parámetros polarimétricos que caracterizan las múltiples fuentes de dispersión típicas de las cubiertas de vegetación y por lo tanto permiten estimar la biomasa de los cultivos con mayor precisión.

En cuanto al monitoreo de pastizales a través de marcadores satelitales (redes neuronales), la propuesta realizada por R. D'Andrimont et al. [33] trata de la combinación de datos SAR de Sentinel-1 (S-1) y observaciones multiespectrales de Sentinel-2 (S-2), para la identificación

de parcelas declaradas como pastizales que potencialmente no son pastizales en la zona de Gelderse Vallei (Países Bajos). Los marcadores satelitales basados en la clasificación de aprendizaje profundo según el tipo de cultivo utilizan datos de retrodispersión y coherencia de S-1 para detectar parcelas con pastizales; y a través de imágenes S-2 se identifica suelo desnudo (parcelas aradas) durante la temporada de crecimiento de los pastizales. El mejor marcador se obtuvo combinando S-1 y S-2 detectando parcelas declaradas erróneamente como praderas con una precisión del 98 %, cuando se combinan ambos sensores.

Siguiendo el análisis de la dinámica de la vegetación, Stendardi et al. [34] escogieron datos SAR en la banda C (S-1) con polarizaciones VV y VH combinados con datos ópticos (S-2) para la detección de etapas fenológicas en diferentes tipos de coberturas como pastizales, praderas, viñedos en zonas de montaña en la región de Tirol del Sur al norte de Italia. A través de un modelo semi-empírico llamado Water Cloud Model (de sus siglas en inglés WCM) se representó la potencia retrodispersada por todo el dosel como la suma incoherente de la contribución de la vegetación y el suelo [35]. La inclusión del NDVI en el modelo permite comprender la contribución de la vegetación en el canal VH. Cabe aclarar que para este caso se optó en usar el canal VH ya que describe mejor las fases fenológicas de las praderas, donde el coeficiente de retrodispersión σ^0 (VH) aumenta bruscamente durante la fase de rebrote de la vegetación, es estable durante la fase reproductiva y disminuye rápidamente en la etapa de cosecha. Los resultados de la comparación entre los valores predichos por las series de tiempo WCM y σ^0 (VH) muestran que el modelo es adecuado para describir la vegetación en áreas montañosas. Concluyendo además que la combinación de datos SAR (S-1) con datos ópticos (S-2) es factible para estimar las etapas fenológicas de la vegetación de montaña.

En la actualidad, para lograr el mapeo de cubiertas vegetales de la superficie terrestre, ha cobrado importancia dentro del campo de la teledetección el uso de diferentes técnicas de clasificación. En el trabajo de investigación de Krishnaswamy et al. [36] se analizaron bosques tropicales compuestos por un ecosistema biológico heterogéneo, donde se usaron imágenes satelitales ópticas en diferentes fechas. Se obtuvo en cada imagen el índice NDVI utilizado como estimador de biomasa verde de la vegetación existente, luego por medio del clasificador Mahalanobis Distance se mapearon los bosques en dos escalas espaciales diferentes. El estudio a escala fina cubrió un área de unos 500 km², mientras que el estudio de escala más amplia abarcó unos 15.000 km². Los datos de verdad de campo se tomaron en diferentes parcelas ubicadas alrededor de Western Ghats, al suroeste de la India. Se obtuvieron correlaciones positivas del clasificador Mahalanobis Distance, pero dependiente de la escala analizada ($R_m=0.63$ para la escala fina y $R_m=0.70$ para la escala gruesa), para cuantificar la variabilidad florística entre las parcelas analizadas.

A. Smith y J. Buckley [37], analizaron la eficiencia de los clasificadores usando un sensor de radar RADARSAT-2 con imágenes full polarimétricas adquiridas en dos ángulos de incidencia y procesadas utilizando el modelo de descomposición Freeman Durden [38], en comparación de una imagen óptica proveniente del sensor Landsat-5 Thematic Mapper. Se mapearon pastizales naturales y mejorados, barbecho de verano y cultivos agrícolas sobre un sitio de prueba en el sur de Alberta, Canadá. Se realizó una clasificación Decision Tree con ambos sensores y solo una imagen del conjunto analizado de RADARSAT-2 (julio de 2009) proporcionó resultados razonables ($Kappa = 0,65$), pero un poco menos preciso en comparación con una imagen de Landsat-5 cuyo valor Kappa fue 0,81. A pesar de ello, debido a las similitudes de retrodispersión entre las coberturas de pastizales naturales y mejorados, RADARSAT-2 fue capaz de discriminar con éxito entre éstos y los cultivos agrícolas. El ángulo de incidencia de la adquisición no tuvo efecto significativo en la discriminación de los cultivos con respecto a los pastizales.

En un estudio reciente, T. Whelen y P. Siqueira [39] experimentaron sólo con imágenes Sentinel-1 (banda C), seleccionando las polarizaciones VV y VH, individualmente y combinadas, para ejecutar clasificaciones supervisadas de coberturas agrícolas y pasturas en una zona de Dakota del Norte, Estados Unidos. La información de la verdad sobre el terreno para la capacitación y validación de la clasificación, provino de un producto publicado por el USDA (CDL). Se efectuaron varias pruebas con el algoritmo analizando precisión de las polarizaciones, las iteraciones y campos de entrenamiento. Los resultados demuestran que, la polarización VH fue ligeramente superior a la polarización VV en las pruebas de iteración única, mientras que la combinación de ambas proporcionaron una precisión ligeramente mayor al considerar todos los ensayos. La mejor clasificación lograda con el menor costo computacional fue con veinte campos de entrenamiento y tres iteraciones en la construcción del modelo, con precisiones generales superiores al 90%.

A partir de los resultados obtenidos en los distintos trabajos de investigación antes mencionados se destaca el uso de la teledetección con sus ventajas y limitaciones para lograr la estimación de la biomasa de los pastizales, como así también, el mapeo de las diferentes áreas donde se distribuyen. Donde el uso de imágenes ópticas han demostrando que el índice NDVI tiende a saturarse con cubiertas vegetales densas. Por otro lado, las imágenes de radar no se han utilizado ampliamente para aplicaciones en pastizales, y se necesita una mejor comprensión del comportamiento de la retrodispersión desde diferentes etapas fenológicas para productos más confiables por ejemplo en las regiones con mucha nubosidad. Por lo cuál, nos encontramos con una problemática aun no resuelta, a partir de la cual se origina nuestra temática de investigación.

2.2. Teledetección

La teledetección satelital es una técnica que permite adquirir imágenes de la superficie terrestre, marina o de los perfiles atmosféricos, desde sensores instalados en plataformas espaciales para su posterior tratamiento e interpretación. Para que dicha técnica pueda cumplir con su propósito de medición del objeto, se precisa que haya un flujo de información entre éste y el sensor (figura 2.1). Este flujo de energía que percibe el sensor recibe el nombre de radiación electromagnética y puede provenir del propio objeto o emitida por el sensor y posteriormente receptada después de haber sido reflejada por diferentes objetos de la superficie terrestre [40]. De esta manera se distinguen dos técnicas para la adquisición de datos, la teledetección pasiva que solo recepta la energía reflejada o transmitida desde el sol en la superficie de la Tierra a través de sensores acoplados en plataformas aeronáuticas o espaciales, mientras que la teledetección activa implica la energía emitida desde un satélite, una aeronave, o cualquier otra plataforma, y receptada por el mismo luego de interactuar con objetos del medio ambiente independiente de la fuente solar [41].




Figura 2.1: Sistema de teledetección pasiva (superior) y activa (inferior) [42]

La luz o el flujo radiante en forma de energía electromagnética se transmite de un lugar a otro a la velocidad de la luz ($3 \times 10^8 \text{ cm s}^{-1}$), la cual se comporta como una onda que contiene dos campos de fuerzas ortogonales entre sí, el eléctrico y el magnético (figura 2.2) [43].

La energía electromagnética puede ser descrita no sólo en términos de longitud de onda (distancia entre cresta y cresta de dos ondas adyacentes) y frecuencia (número de ondas emitidas por unidad de tiempo), sino también en unidades de energía fotónica como joules (de su sigla en inglés J) y electrón voltios (de sus siglas en inglés eV) [44].




Figura 2.2: Esquema de una onda electromagnética [44]

En la física, se denomina espectro electromagnético al rango de radiaciones que se caracterizan en función de la frecuencia, la longitud de onda y la energía de dichas radiaciones. Este espectro se divide en rangos o bandas que se caracterizan por cierta homogeneidad energética. En la teledetección la región más utilizada es la del espectro visible (entre $0.4 \mu\text{m}$ y $0.7 \mu\text{m}$) para el análisis del estado fenológico de la vegetación; la región del infrarrojo cercano (entre

0.7 μm y 1.3 μm), permite captar mejor la vegetación sana que depende de los pigmentos presentes en las hojas, las características morfológicas de las plantas y concentraciones de humedad en las mismas; el infrarrojo medio (entre 1.3 μm y 8 μm) y el infrarrojo lejano (entre 8 μm a 14 μm) que resultan idóneos para el análisis del contenido de agua en los tejidos vegetales y en los suelos. Finalmente en la región del espectro dominada por las longitudes de onda milimétricas y centimétricas se encuentran las microondas (entre 10^{-1} m y 10^{-3} m), en este rango o dominio existe alta sensibilidad en cuanto a la estructura y geometría de las plantas, como así también, a la rugosidad superficial, al contenido de humedad de la vegetación y el suelo. La virtud fundamental de esta región del espectro y a diferencia de las anteriores es que posee un una longitud de onda que puede penetrar la cubierta nubosa, la niebla y la lluvia [40] (figura 2.3).

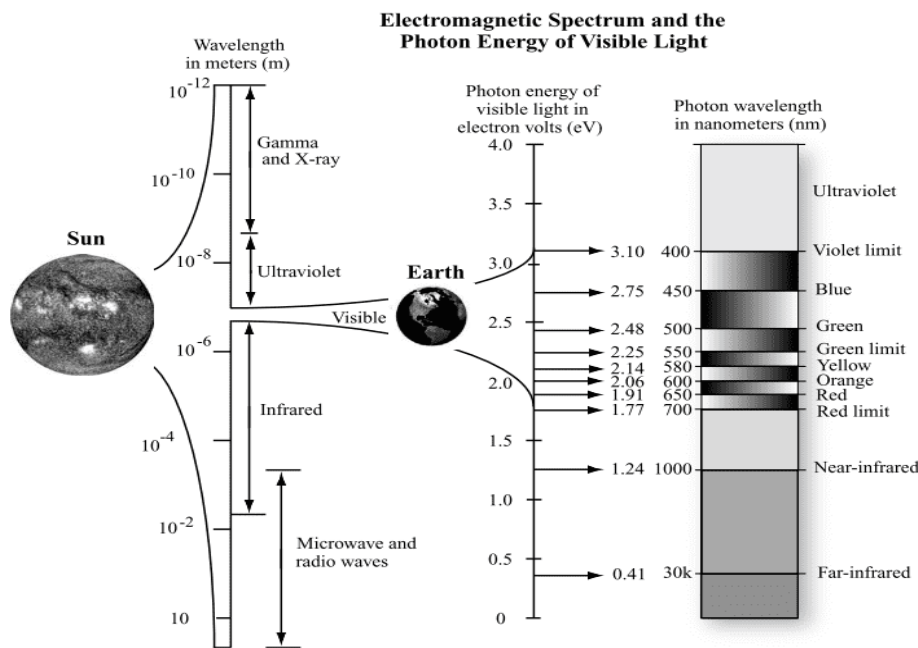


Figura 2.3: El espectro electromagnético y la energía fotónica de la luz visible [44]

En la figura 2.4 se muestra el ejemplo típico de la firma de reflectancia espectral para la vegetación. Esta curva proporciona información de la energía radiante reflejada, entendiéndose que lo que no se reflejó se absorbió o transmitió. Esta información sigue siendo bastante valiosa y puede constituir la base para la identificación y evaluación de diferentes coberturas (pasturas, bosques, suelo desnudo, cuerpos de agua) [44].

Se observa en la figura 2.4 que la curva de reflectancia exhibe una configuración de "picos y valles". Donde los picos indican una fuerte reflexión de la energía incidente y los valles indican la absorción predominante de la energía en las correspondientes bandas de longitud de onda. La primer porción se encuentra la región visible, llamado así porque es la única radiación electromagnética que puede detectar nuestros ojos (0,4 a 0,7 μm). Aquí, la clorofila absorbe fuertemente la luz en longitudes de onda alrededor de 0.45 (azul) y 0.67 μm (rojo) para la fotosíntesis y se refleja fuertemente en la luz verde, por lo que nuestros ojos perciben la vegetación saludable como verde.

La banda amarilla recoge un detalle un poco más fino de la porción del espectro (0,585-0,625 μm) la cual detecta la clorosis de las hojas en plantas estresadas. Además, ante la presencia de una vegetación con estrés la firma espectral diferirá debido a la variación en la

pigmentación de las hojas. Aproximadamente a $0,7 \mu\text{m}$ en la región de transición rojo-NIR, se la denomina 'borde rojo' que marca el límite entre la absorción por clorofila en la región visible (rojo) y la dispersión debida a la estructura interna de la hoja en la región NIR donde la reflectancia de la vegetación sana aumenta drásticamente. Esta región es muy utilizada en la actualidad para el análisis de sanidad de las plantas. En el rango que va desde $0,7$ a $1,3 \mu\text{m}$ (infrarrojo cercano), la hoja de una planta refleja típicamente entre el 40 y el 50 por ciento de la energía que incide sobre ella dependiendo de las características estructurales de la misma [41]. A partir de $1,3 \mu\text{m}$ hasta $2,5 \mu\text{m}$ en la región del infrarrojo medio (por sus siglas en inglés MIR), la reflectancia está relacionada con el contenido de agua de la vegetación y su estructura. Se observa en la figura dos valles alrededor de $1,4$ y $1,9 \mu\text{m}$, donde la reflectancia se ve afectada, lo que hace que sea ideal para entender el estrés hídrico de los cultivos [45].




Figura 2.4: Curva de reflectancia típica de la vegetación, mostrando los factores dominantes que controlan la reflectancia de la hoja [41]

La radiación solar es la radiación electromagnética emitida por el sol, que penetra en la atmósfera de la Tierra, para luego interactuar con la superficie terrestre y reflejar la luz de vuelta al sensor. En dicho recorrido, este flujo de energía interactúa con agua (H_2O), dióxido de carbono (CO_2), oxígeno (O_2), ozono (O_3), óxido nítrico (N_2O) y otros gases que representan un obstáculo para su transmisión. Estos gases atmosféricos absorben la radiación solar en sectores del espectro electromagnético (EMM) perjudicando el proceso de transmisión de energía, lo que es perjudicial para la detección remota ya que no hay energía disponible para ser detectada [44]. Por lo cual, para el diseño de sensores remotos se utilizan aquellas bandas del EMM donde la atmósfera es transparente (poca o ninguna absorción de radiación) a longitudes de onda específicas. Estas bandas se las conocen como "ventanas atmosféricas" ya que permiten que cierta parte del EMM se pueda transmitir fácilmente a través de la atmósfera a la superficie de la Tierra con mínimas interferencias en relación al fenómeno en estudio [40].

En la figura 2.5 se observa las diferentes longitudes de onda en las que la radiación electromagnética penetra en la atmósfera terrestre sin mayores inconvenientes (ventanas atmosféricas) como así también las bandas de absorción.




Figura 2.5: Ventanas atmosféricas y bandas de absorción [46]

2.3. Radar de Apertura Sintética

2.3.1. Definición, concepto de funcionamiento y geometría de adquisición de un SAR

El Radar de Apertura Sintética (SAR, por sus siglas en inglés) es un sistema activo montado en vehículos espaciales y aéreos cuyo sensor produce su propia energía, transmitiendo señales de microondas a la Tierra con el objetivo de registrar su retorno una vez reflejado por la superficie y obteniendo así imágenes de alta resolución a larga distancia [47]. A diferencia de los sensores ópticos, el SAR tiene la capacidad de observar objetos a través de las nubes y, parcialmente, a través de las precipitaciones (dependiendo de la banda utilizada); la energía de radar retrodispersada desde un objeto es diferente a la energía óptica, poseen alta sensibilidad a la humedad, rugosidad, a las estructuras geométricas y orientación de los blancos con los que interactúa como las plantas y el suelo [48]; además, la última generación de sensores SAR dispone de productos con una mejor resolución espacial, con lo cuál, el dominio de aplicaciones de los sensores de radar se ha ampliado complementando a las fuentes de datos ópticos [15].

Los radares utilizan microondas para medir distancias (alcance) en un período pequeño de tiempo, a medida que la plataforma del radar recorre su trayectoria en forma uniforme va emitiendo y recibiendo los ecos de la señal retrodispersada en los objetos dando lugar a una apertura sintética, es decir, debido a la gran velocidad de desplazamiento del vehículo espacial, la antena del dispositivo SAR se convierte en una antena virtual que logra el mismo rendimiento obtenido por una antena mucho más grande que la que posee en realidad. Los ecos recibidos son digitalizados, almacenados y posteriormente procesados para construir una imagen de la superficie del suelo (región de interés) [49].

En la figura 2.6 se muestra la geometría de adquisición de un sistema SAR, donde el objeto de estudio es alcanzado por el haz de la antena permaneciendo en la misma durante unos instantes en el que es observado por el radar desde numerosos puntos a lo largo de la trayectoria de satélite también llamada dirección de acimut, almacenando los múltiples ecos recibidos [50]. La distancia que existe entre el sensor radar y el blanco en la superficie de la tierra en dirección perpendicular al vuelo, se denomina rango o alcance.

La distancia más cercana, respecto del sensor, a la que se encuentran los blancos iluminados es denominada rango cercano, mientras que la mayor distancia es denominada rango lejano. El ancho de la superficie que es iluminada por el SAR es llamado ancho de barrido o ancho del haz, localizado entre los rangos cercano y lejano. El mismo está definido por un ángulo de mirada (entre la vertical desde la antena hasta el suelo y la línea de vista del radar) [51].




Figura 2.6: Vista general de la geometría de un SAR [52]

Se puede observar en la figura 2.6 que además se genera otro ángulo entre el pulso que emite el sensor y la línea perpendicular a la superficie de la Tierra donde hace contacto con el blanco, llamado ángulo de incidencia, el cual se define a partir de una línea imaginaria del nadir del blanco [48].

El ángulo de incidencia es el parámetro más importante para describir la geometría relativa entre el radar y la escena observada. Un cambio en el ángulo de iluminación del radar a menudo afecta el comportamiento de retrodispersión del radar de una superficie u objetivo, donde los retornos de la señal son normalmente fuertes en ángulos de baja incidencia y disminuyen al aumentar el ángulo de incidencia. Tal es el caso de una superficie plana donde el cambio de ángulo tiende a ser bastante pequeño, pero para una superficie inclinada (pendiente), toma relevancia el ángulo de incidencia local definido como el ángulo entre el haz incidente del radar y una línea que es normal a esa superficie. El ángulo de incidencia local determina, en parte, el brillo o el tono para cada elemento de una imagen. Es un elemento clave en la interpretación prominente de las características del terreno en las imágenes de radar como las áreas montañosas [51].

Además del ángulo de incidencia, otros parámetros importantes del sensor considerado para el desarrollo de modelos que puedan caracterizar correctamente el coeficiente de retrodispersión de los objetos que se desean identificar o estudiar, son la longitud de onda y frecuencia del radar.

En la tabla 2.1 se observa las longitudes de onda y frecuencias más comúnmente utilizadas en las imágenes de radar, las cuales se clasifican de manera arbitraria en bandas identificadas por letras [44]. Estas bandas fueron adoptadas por algunos de los sensores actualmente en órbita: la banda-X fue utilizada para los sensores COSMO-SkyMed y TerraSAR-X; la banda-C, en sensores Sentinel-1 y Radarsat-2; y la banda-L, en sensores ALOS-2 y SAO-COM.

Tabla 2.1: Bandas, longitudes de onda y frecuencias del EMM (microondas) [44]

Bandas de Radar	Longitudes de onda (cm)	Frecuencia (GHz)
Ka	0.75 – 1.18	40.0 – 26.5
K	1.19 – 1.67	26.5 – 18.0
Ku	1.67 – 2.4	18.0 – 12.5
X	2.4 – 3.8	12.5 – 8.0
C	3.9 – 7.5	8.0 – 4.0
S	7.5 – 15.0	4.0 – 2.0
L	15.0 – 30.0	2.0 – 1.0
P	30.0 – 100	1.0 – 0.3

Dependiendo del producto a obtener se optará por seleccionar para el análisis determinada longitud de onda del radar. Para el estudio de las estructuras de la vegetación, la penetración de la señal a través del follaje es mayor mientras más larga sea la longitud de onda (frecuencias bajas). En la figura 2.7 se presenta una comparación de la respuesta de la energía de microondas incidente para las bandas X, C, L y P sobre un mismo dosel.

La energía de la banda-X de longitud de onda más corta (3 cm) se atenúa más por la dispersión de la superficie en la parte superior de un dosel interactuando con el follaje y las ramas pequeñas. Entendiéndose por dosel o cubierta vegetal, al entramado formado por la disposición espacial de las hojas, ramas y troncos de los vegetales superiores. La energía de la banda-C (6 cm) penetra en la parte superior del dosel, dominada por una dispersión de volumen (ramas y hojas pequeñas) y poca energía llega al suelo. La banda-L corresponde a una longitud de onda de 24 cm, que se caracteriza por una gran profundidad de penetración y está dominada por procesos de dispersión que involucran a los principales componentes de la biomasa leñosa (troncos, ramas y hojas de tamaño mas grandes) y la superficie del suelo. La longitud de onda más larga es la banda-P (65 cm), permite la mayor penetración a través de la vegetación y se reflejaría principalmente en los tallos grandes y pueden transmitirse numerosos pulsos al suelo, donde puede tener lugar la dispersión superficial de la capa límite suelo-vegetación [53].




Figura 2.7: Sensibilidad de las mediciones de SAR a la penetración en el dosel según diferentes longitudes de onda utilizadas [53]

Como se mencionó anteriormente la señal de radar emite ondas EM las cuales están compuestas por campos eléctricos y magnéticos (perpendiculares entre sí), que actúan como una sola unidad, y están situados en un plano normal a la dirección de propagación.

Las antenas de los sistemas de radar están configuradas para transmitir y recibir radiación electromagnética polarizada en forma horizontal o vertical. Cuando la energía transmitida es polarizada en la misma dirección que la recibida, al sistema se lo conoce como de polarización similar (copolarizada), donde la energía se transmite y se recibe horizontalmente polarizada (HH), o se transmite y se recibe verticalmente polarizada (VV), como se observa en la figura 2.8. El último modo se denomina polarización cruzada (crosspolarizado), donde las microondas del campo eléctrico transmiten las señales verticalmente y la antena recibe el campo eléctrico polarizado horizontalmente de la energía retrodispersada (VH) o viceversa (HV) [47].




Figura 2.8: Planos de copolarización de la onda EM [54]

Así existen sensores que operan con polarización completa también denominado full polarimétrico o quad-pol, como el caso de los satélites SAOCOM, donde el sistema radar emite alternadamente ambas polarizaciones lineales tanto H como V y las recibe simultáneamente, en modo HH, HV, VH y VV. Esto significa que un blanco de la superficie tendrá cuatro respuestas diferentes para cada tipo de polarización. Las imágenes de radar con polarización múltiple son una aplicación especialmente útil de energía polarizada [55]. A través de ésta polarización múltiple se logra extraer información de las propiedades físicas de las superficies observadas para su caracterización. Como por ejemplo para el análisis de humedad del suelo, la bibliografía indica que las polarizaciones HH y VV resultan de las más indicadas para la estimación de este parámetro [56]. La banda de polarización cruzada (VH), permite un mejor análisis de la contribución de la vegetación con respecto al componente suelo cuando la misma se encuentra en un estado fenológico reproductivo (desde floración hasta maduración de los frutos) [57], [58], [34].

2.3.2. Interacción de la radiación electromagnética con la materia

Los sistemas SAR envían pulsos lateralmente y gracias a esta oblicuidad, el radar puede devolver al sensor las señales de los distintos objetos de la Tierra en diferentes momentos, lo que permite discriminarlos. Pero debido a las irregularidades que presenta la superficie de contacto (especialmente en áreas de montaña o de relieve pronunciado), dicha señal se verá afectada generando distorsión geométrica en la imagen. Tres son las principales distorsiones que hallamos en las imágenes SAR: Foreshortening, Layover y Shadow (ver figura 2.9).

Foreshortening o acortamiento frontal, se manifiesta en todo aquel terreno que tenga una pendiente inclinada hacia el radar, el cual aparecerá comprimido o acortado en relación con las pendientes inclinadas mas alejadas a la detección del radar. Los objetos afectados se observan en la imagen con una apariencia más brillante.

El layover o inversión por relieve se produce cuando dicho relieve modifica la posición con la que aparecen dos objetos en la imagen, a consecuencia de que sus ecos lleguen al sensor en forma inversa a su posición respecto a la trayectoria. Como por ejemplo una montaña, donde se observa en su parte superior un desplazamiento respecto de su base. Estos efectos pueden corregirse usando un modelo digital del terreno [47].

Finalmente shadow o sombreado se presenta cuando la señal del radar no puede iluminar la superficie del suelo. Las sombras se producen en la dimensión de rango inferior (es decir, hacia el rango lejano), detrás de entidades verticales o pendientes con lados empinados (edificios, montañas). Dado que la señal del radar no ilumina la superficie, las regiones sombreadas aparecerán con tonos muy oscuros en una imagen ya que no hay energía disponible para ser retrodispersada presentando dicha región la pérdida completa de información [54].

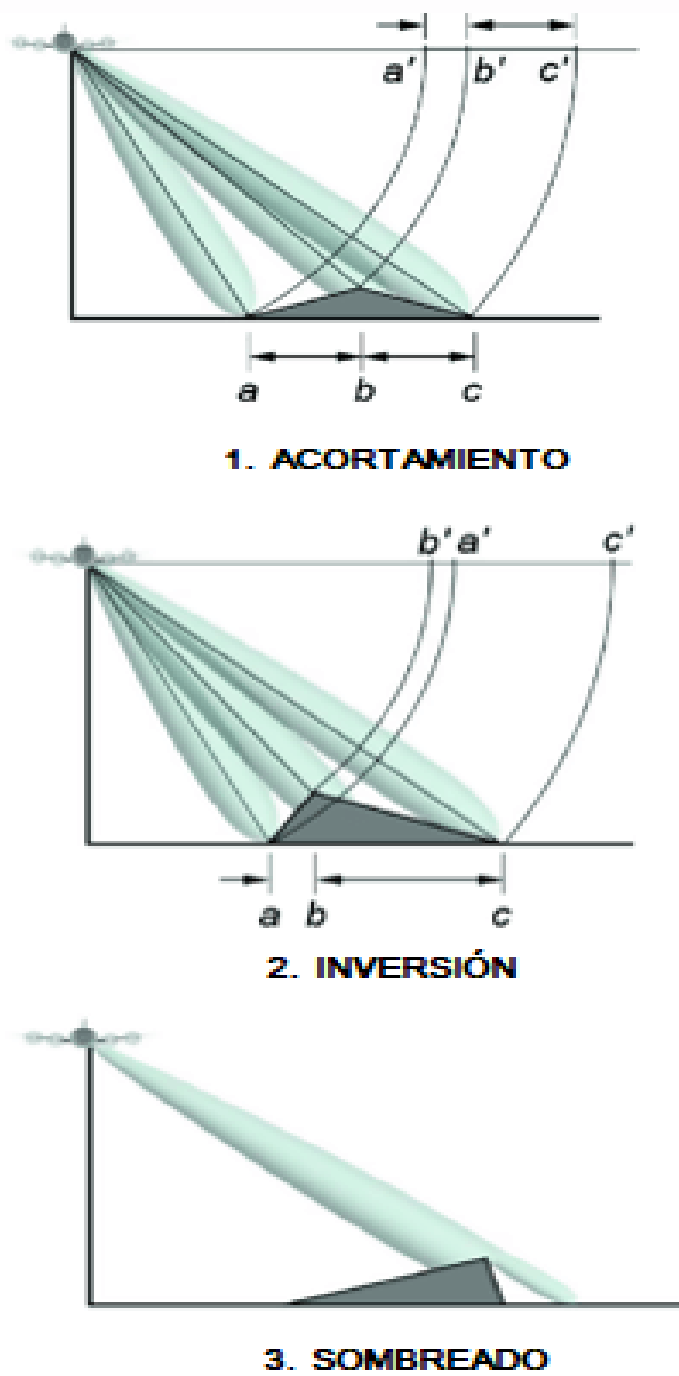


Figura 2.9: Distorsiones geométricas generadas en una imagen SAR. 1) Acortamiento: a la distancia real $a-b$ le corresponde en la imagen una distancia mucho menor $a'-b'$; 2) Inversión: el segmento de terreno $a-b$ aparece en la imagen invertido $b'-a'$; 3) Sombreado: un segmento del terreno nunca es alcanzado por la señal del radar [59]

Capítulo 3

Área de estudio

3.1. Sitio experimental

3.1.1. Región de Entre Ríos (Argentina)

La zonas de estudio principales se encuentran en la región centro-norte y región centro-sur de la provincia de Entre Ríos (Argentina) la cual está localizada entre los ríos Paraná y Uruguay (figura 3.1). Junto a las provincias de Corrientes y Misiones conforman la región geográfica denominada Mesopotamia. Limita al Norte con la provincia de Corrientes, al Oeste y Sudoeste con Santa Fe, al Sur con Buenos Aires y al Este con la República Oriental del Uruguay. De la superficie total correspondiente a la provincia de Entre Ríos (78.781 km²), unos 16000 km² se corresponden con la zona de estudio. Se encuentra situada entre los 30° 10' y 32° 40', de latitud sur y entre los 58° 15' y 59° 52' de longitud oeste. Las áreas propuestas para el análisis de pastizales naturales se conforman de sistemas productivos de cría, constituyendo la base forrajera principal para la alimentación del ganado.

3.1.1.1. Fitogeografía

La vegetación típica en la región centro-norte de la provincia de Entre Ríos es tipo monte semixerofítico, con un estrato arbustivo y otro herbáceo, muy rico en especies que pertenecen en su mayoría a la flora pampeana. Las especies herbáceas dominantes pertenecen a los géneros *Piptochaetium*, *Paspalum* y *Stipa* [60].

En los últimos años muchas de estas áreas naturales fueron reemplazadas por pasturas implantadas que año a año van sustituyendo a las especies nativas. Además, es frecuente observar la invasión de especies leñosas y malezas arbustivas (*Eupatorium buniifolium*, *Eryngium paniculatum*, *Baccharis salicifolia*, *Baccharis punctulata*, *Baccharis articulata*), debido al manejo inadecuado del ganado y al sobrepastoreo. Teniendo en cuenta la influencia del relieve, éste configura características diferenciales en la dinámica de los pastizales. En áreas deprimidas a cóncavas, la retención de agua superficial y el impedimento del drenaje, dan condiciones de pastizales en forma de matas y de alto porte por lo que el paisaje puede presentar características heterogéneas.

Áreas de estudio: Región de Entre Ríos (Argentina)

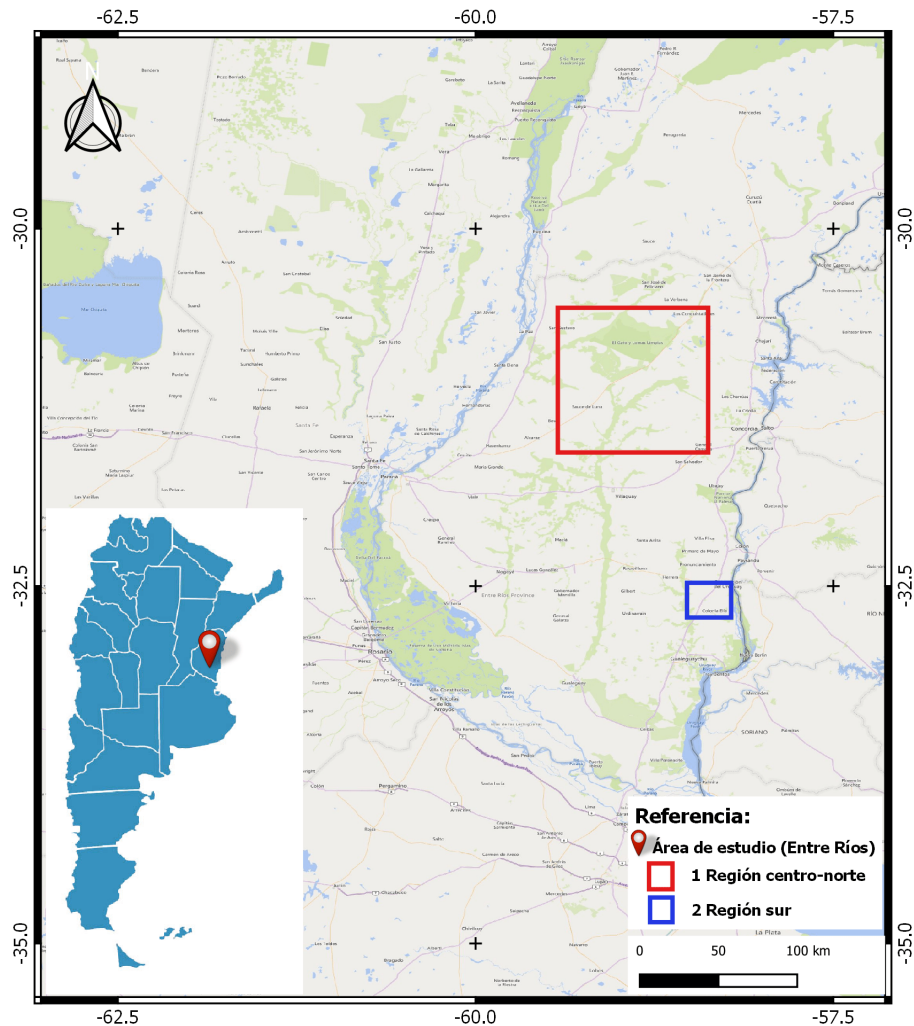


Figura 3.1: Área de estudio principal para la identificación y mapeo de los pastizales (región centro-norte de Entre Ríos, Argentina) y para la estimación de biomasa de los pastizales (región sur de Entre Ríos, Argentina) [61]

3.1.1.2. Clima

La provincia de Entre Ríos se encuentra ubicada dentro de los climas de dominio atlántico. Está dividida en dos regiones climáticas debido a la existencia de un gradiente térmico que acusa las variaciones latitudinales de la radiación solar, sumadas a las marcadas diferencias hídricas: una pequeña franja al norte de la provincia que abarca los departamentos de Federación, Feliciano, Federal, y el norte de La Paz, se corresponde con el clima Subtropical húmedo de llanura. Posee una temperatura media anual alrededor de 20 °C, se caracteriza por inviernos benignos donde la amplitud térmica no alcanza valores altos y veranos cálidos con temperaturas medias altas. Las precipitaciones anuales para esta zona rondan entre 1200 a 1300 mm [62].

El resto de la provincia (centro y sur) se caracteriza por poseer un clima Templado húmedo de llanura, sin situaciones extremas. El régimen térmico es templado, con una temperatura media anual de 17,6 °C con mayor amplitud térmica en su parte norte, debido a su distancia de los ríos. En esta zona las lluvias representan un factor clave en la producción agrícola (precipitaciones anuales entre 900 y 1100 mm), en concordancia con las características de los suelos y de los cultivos implantados (cultivos de secano de cereales y forrajeras) [63].

3.1.1.3. Características edáficas

Se distinguen dos zonas de interés dentro de la provincia de Entre Ríos, una pequeña área seleccionada para el análisis estimativo de la biomasa de los pastizales (región centro-sur) y la otra para la identificación y mapeo de pastizales naturales (región centro-norte).

La primera, se encuentra localizada al sur de la Estación Experimental Agropecuaria Concepción del Uruguay rodeado por el arroyo 'La China' que corre en dirección hacia el Río Uruguay. El paisaje es suavemente ondulado compuesto mayormente por pendientes 1-2% que llegan hasta 4% en algunos lugares. Dicha zona está situada sobre un sustrato de arenas y areniscas terciarias que afloran en los valles. No se encuentran calizas que son comunes en cercanías de la costa del Río Uruguay. Superpuestos a la arenisca están los limos pampeanos, gredas arcillo-limosas, pardas, calcáreas de origen volcánico. Debido a estas condiciones el drenaje se ve limitado en suelos limosos ocasionando gran escorrentía. En la zona de lomas se encuentran suelos desarrollados sobre limos pampeanos, algunos con perfiles uniformes arcillosos y con micro-relieve gilgai (Vertisoles). En las lomas medias y bajas los suelos poseen textura arenosa y franco arenosa superficial, con una capa de arcilla a profundidad variable que limita el drenaje [64].

La zona de estudio seleccionada para la identificación y mapeo de pastizales naturales se encuentra ubicada alrededor del departamento de Feliciano (centro-norte de Entre Ríos). En ésta región la topografía de los suelos se ubica en zonas planas a muy poco onduladas; son imperfectamente drenados y después de las lluvias quedan con exceso de agua en la superficie. Poseen un epipedón de poco espesor de textura limosa, al que le sigue un horizonte impermeable y con dificultad para la penetración de las raíces, de textura franca arcillo-limosa. No tienen peligro de erosión, pero el exceso periódico de agua en la superficie y las características físico-químicas adversas, reducen su aptitud y capacidad productiva [65].

3.1.2. Región de Val Mazia (Italia)

De igual manera, replicando el comportamiento de las distintas variables derivadas de datos ópticos y SAR en el proceso estimativo de la biomasa de los pastizales, se seleccionó un área de estudio secundaria como se muestra en la figura (3.2), ubicada en la región de Val Mazia (situada en la parte occidental del Alto Adige) al norte de Italia limitando con Austria. Geográficamente dicha región se encuentra en el centro de los Alpes y presenta un gradiente de altitud pronunciado que oscila desde 200 metros a los 3890 metros sobre el nivel del mar constituido por una compleja topografía. En este caso, el área de estudio se encuentra localizado a una altura de 1500 metros sobre el nivel del mar.

Área de estudio: Región de Val Mazia (Italia)

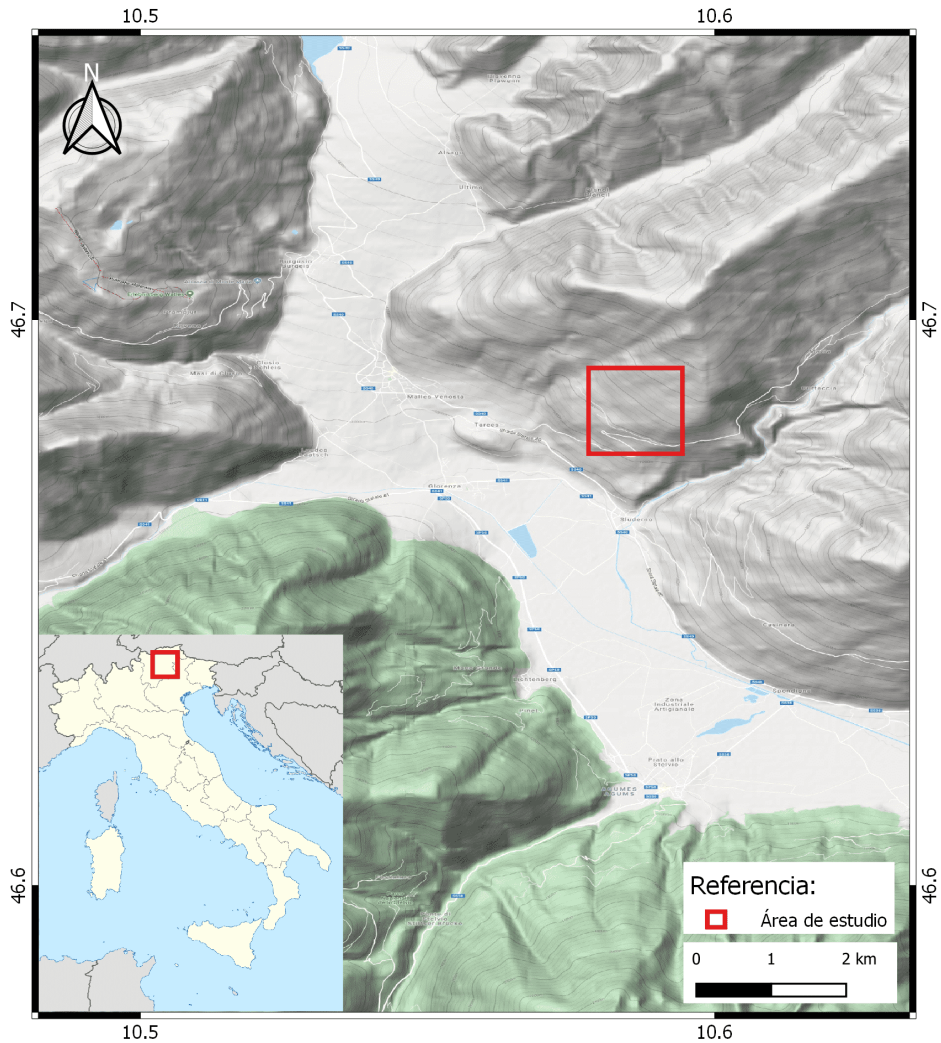


Figura 3.2: Área de estudio secundaria para la estimación de biomasa de los pastizales: Val Mazia, Italia [61]

3.1.2.1. Clima

Las condiciones climatológicas son representativas de las diferentes zonas alpinas: las precipitaciones alcanzan su máximo en las zonas prealpinas del norte y del sur (hasta 2200 mm/año), mientras que la región interior es más seca (menos de 600 mm/año en la región de Venosta). La mayoría de los ríos en la parte central y norte de la región considerada tienen un régimen nivo-glacial con descarga máxima durante los últimos meses de verano [66].

3.1.2.2. Fitogeografía

La región se caracteriza por un típico clima de montaña compuesto por un paisaje muy heterogéneo, mas de la mitad de la superficie está cubierta de bosques, predominantemente de piceas (*Picea abies*) y pinos (*Pinus sylvestris*, *P. cembra*), acompañados de bosques mixtos con hayas (*Fagus sylvatica*) y abetos (*Abies alba*). Un tercio de la región está cubierto por tierras agrícolas, pasturas implantadas, huertos y viñedos, el 14% por pastizales alpinos, glaciares y zonas rocosas [67].

Los pastizales se pueden encontrar en todos los cinturones de elevación en toda Italia cuya distribución se intercala frecuentemente con arbustos y árboles. Se distinguen en las zonas bajas de los valles debajo de los 1000 metros sobre el nivel del mar, especies de festucas o pastos pluma frecuentemente muy secos. Entre 1000 y 1800 metros sobre el nivel del mar se encuentran pastizales mesicos, donde especies como *Violin caninae* crecen en suelos ácidos y pobres en nutrientes o las especies de *Cynosurion* que habitan en suelos ricos en nutrientes con pH intermedio. A mayor altitud (entre 1800 y 2300 metros sobre el nivel del mar), el aspecto cambia y los pastizales de *Nardus* toman el relevo, estos pastizales son famosos por su rica variedad de flores. En las áreas con suelos más húmedos y ricos en nutrientes, podemos encontrar pastizales dominados por especies forrajeras como *Poa alpina* y *Phleum rhaeticum* [68].

Capítulo 4

Materiales y Métodos

4.1. Adquisición de imágenes satelitales

4.1.1. Imágenes Sentinel-1

Las imágenes radar en banda C (Sentinel-1) adquiridas para la región de estudio en Entre Ríos, Argentina (correspondientes con el año 2018), fueron provistas por el Instituto de Observación de la Tierra (EURAC Research), Bolzano, Italia.

Los productos solicitados son de tipo Nivel 1 GRD (por sus siglas en inglés Ground Range Detected) de alta resolución espacial (HR). Los productos GRD están calibrados y ortorectificados utilizando un modelo elipsoide de la Tierra (elipsoide WGS84). Dicha proyección elipsoidal se corrige utilizando la altura del terreno que es constante en el rango pero varía en azimut. La información de la fase es descartada. El producto resultante posee un espaciado de píxeles equidistante en azimut y en el rango del suelo con resolución aproximadamente cuadrada. Los valores de píxeles representan la magnitud detectada [69].

Al observar la descripción de las imágenes S-1 adquiridas (acudir al anexo A) se advierte que, todos los productos seleccionados de S-1 poseen el modo de adquisición IW (por sus siglas en inglés Interferometric Wide swath), nivel de procesamiento GRD con doble polarización (VV y VH) cuyos datos se distribuyen en el formato de archivo estándar de Sentinel para Europa (SAFE). Se adquirieron las imágenes en dirección de órbita descendente para poder comparar temporalmente una determinada área con la misma geometría de observación sin tener en cuenta la variabilidad que pueda generar el ángulo de incidencia.

Para el rango de fechas correspondientes con los años 2016 y 2017, se efectuó la solicitud y descarga manual de todas las imágenes desde la plataforma web Copernicus Services Data Hub de la Agencia Espacial Europea (por sus siglas en inglés ESA). Debido a que los productos se encontraban en modo 'offline' (figura 4.1) por lo tanto, no disponibles para la descarga inmediata (imágenes S-1 del año 2018), quedando los mismos disponibles modo 'online' durante un plazo máximo de 3 días desde el momento de aprobación de dicha solicitud.

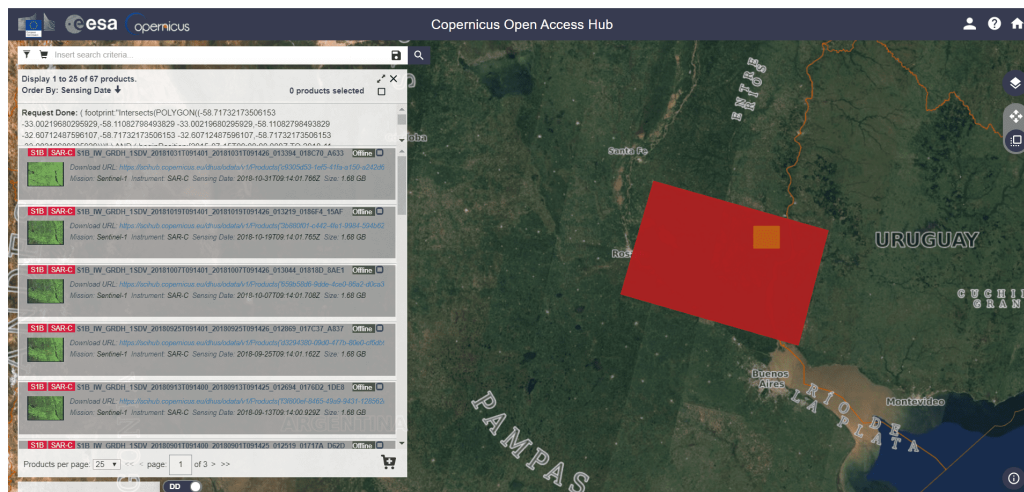


Figura 4.1: Adquisición de imágenes S-1 en modo 'offline' desde el portal de la ESA del área de estudio en Argentina [49]

En cuanto a la adquisición de las imágenes de S-1 para la zona de estudio en la región de Val Mazia, provincia de Bolzano (Italia), las mismas también fueron obtenidas desde la plataforma web Copernicus Services Data Hub.

Como se observa en el anexo C, los productos seleccionados (desde mayo a octubre del año 2017) poseen el mismo formato que las S-1 solicitadas para la zona de estudio de Argentina (GRD), modo de adquisición IW y doble polarización (VV y VH), diferenciándose solo en el modo de observación de la pasada del satélite la cuál es ascendente en este caso. Cabe aclarar que en función del plan de adquisiciones de la Misión S-1, la revisita del satélite en dicha región es cada 6 días en relación al ciclo de repetición orbital sobre Argentina que es cada 12 días.

4.1.2. Imágenes Sentinel-2

Las imágenes ópticas de Sentinel-2 (S-2) adquiridas para la región de estudio en Entre Ríos, Argentina (correspondientes al año 2018), fueron provistas por el Instituto de Observación de la Tierra (EURAC Research), ubicado en la provincia de Bolzano, Italia. Las mismas poseen un nivel de tratamiento L1C con valores de reflectancia a Tope de la Atmósfera (por sus siglas en inglés TOA). Las imágenes fueron filtradas utilizándose aquellas con un porcentaje de cobertura nubosa menor al 30%.

Para el rango de fechas correspondientes con los años 2016 y 2017, se procedió a la solicitud y descarga manual de todas las imágenes de S-2 (dispuestas en modo 'offline') desde la plataforma web Copernicus Services Data Hub de la ESA (como sucedió en la descarga de las imágenes de radar en dichas fechas), las mismas se visualizan en el anexo A.

Las imágenes de S-2 adquiridas para la zona de estudio en la región de Val Mazia, provincia de Bolzano (Italia), fueron obtenidas desde un servidor del Instituto EURAC Research. La ventana temporal para la descarga de imágenes va desde mayo a octubre del año 2017. Las mismas poseen un nivel de tratamiento L1C con valores de reflectancia a Tope de la Atmósfera (ver descripción de las imágenes en el anexo C).

En este caso también se seleccionaron aquellas imágenes con un porcentaje de cobertura nubosa menos al 30%.

4.1.3. Imágenes Landsat-8

Se procedió a la selección y descarga de las imágenes ópticas de Landsat-8 (L-8) para ambas zonas de estudio (Argentina e Italia), adquiridas desde del portal del Servicio Geológico de los Estados Unidos (USGS por sus siglas en inglés) (figura 4.2). Éstas, poseen un nivel de procesamiento L1T, con corrección radiométrica y geométrica de las escenas.

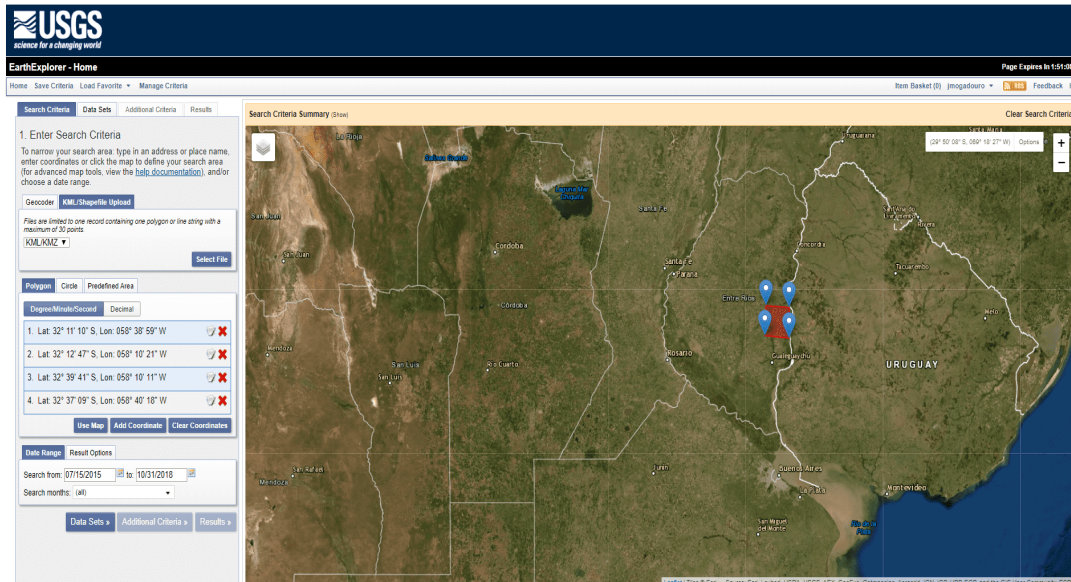


Figura 4.2: Adquisición de imágenes L-8 desde el portal USGS del área de estudio en Argentina [70]

Los productos de reflectancia de superficie de L-8 adquiridos, son generados por el Centro de Ciencia y Observación de los Recursos de la Tierra (por sus siglas en inglés EROS) a una resolución espacial de 30 metros y corregidos atmosféricamente a través de algoritmo desarrollado por la NASA llamado LaSRC (Landsat 8 Surface Reflectance Code) [70]. Las imágenes fueron filtradas seleccionando sólo aquellas que contemplen en la escena un porcentaje de nubes menor al 30%.

En la tabla A.3 (anexo A) se visualizan las imágenes L-8 seleccionadas para el área de estudio en Entre Ríos (Argentina) y en la tabla C.3 (anexo C), aquellas para cubrir el área de interés en Val Mazia (Italia).

4.2. Datos de campo

4.2.1. Región de Entre Ríos, Argentina

Para la construcción de este trabajo de investigación, la información de campo fue aportada por la Estación Experimental Agropecuaria INTA Concepción del Uruguay (Entre Ríos, Argentina) en el marco del proyecto FONTAGRO (ver puntos muestreados de color amarillo en la figura 4.3). Los datos se corresponden con salidas a campo en la zona de estudio centro-norte y sitios experimentales en la región centro-sur de Entre Ríos, en cercanías a la localidad de Concepción del Uruguay (ubicación de los sitios de estudio en color rojo en la figura 4.3), correspondiente a muestras *in situ* de biomasa de los pastizales (MIBIOP), cuyas unidades de medidas son kilogramos de materia seca por hectárea (kgMS/ha).



Puntos de muestreos *in situ* de biomasa de pastizales: Región de Entre Ríos (Argentina)

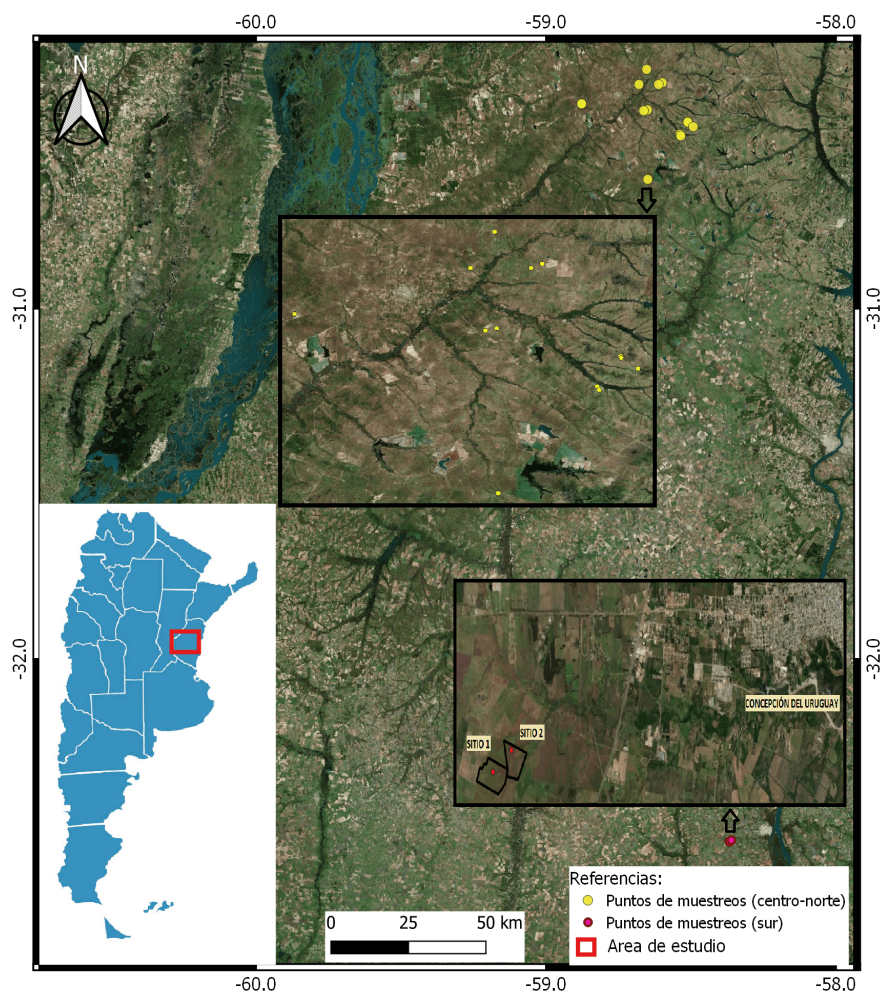


Figura 4.3: Puntos de muestreos a campo (Entre Ríos, Argentina) [61]

Éstos datos fueron utilizados como referencia en el proceso de identificación de las áreas con pastizales y proveen la base necesaria para mejorar la precisión en la estimación de biomasa en dicha región a través de imágenes ópticas y de radar.

La metodología utilizada en la recolección de MIBIOP para la región centro-norte de Entre Ríos, se basa en la estimación alométrica de biomasa de los pastizales a partir de la altura promedio de la vegetación utilizando un modelo de regresión generado por Lucrecia Lezana [71]. El procedimiento consta en realizar alrededor de 50 mediciones de altura de la vegetación por sitio y fecha determinada. En las siguientes figuras (4.4) se observa el paisaje y vegetación típica de los pastizales en la región centro-norte de Entre Ríos.



Figura 4.4: Paisaje y vegetación típica en las zonas muestreadas en la región centro-norte de Entre Ríos, Argentina

Para la obtención de las MIBIOP en la región centro-sur de Entre Ríos, se utilizó la metodología tradicional que implica el corte, secado y pesado de biomasa de los pastizales, tomando muestras en un área de 40 x 40 centímetros por sitio y fecha determinada (4 repeticiones por

sito). Esos datos fueron luego convertidos en unidades de medida de kgMS/ha. En las siguientes figuras (4.5) se observan las áreas muestreadas y la fisiografía característica de la zona.



Figura 4.5: Paisaje y vegetación típica en las zonas muestreadas en la región centro-sur de Entre Ríos, Argentina

4.2.2. Región de Val Mazia, Italia

En cuanto a los datos de campo correspondientes con la región de Val Mazia en la provincia de Bolzano (norte de Italia), fueron proporcionados por el Instituto de Observación de la Tierra - EURAC Research en el contexto de recopilación de datos *in situ* de biomasa de los pastizales para el análisis correspondiente con el año 2017 [72].

Los puntos muestreados de MIBIOP se observan en la figura 4.6. El paisaje y vegetación típica de pastizales en esta región de montañas se visualiza en la figura (4.7). Tener en cuenta que dichas imágenes fueron tomadas en el comienzo del ciclo de crecimiento de la vegetación. Para la obtención de las MIBIOP en dicha zona de estudio, se utilizó la metodología tradicional que implica el corte, secado y pesado de biomasa de los pastizales, cuyas unidades de medida finales fueron en kgMS/ha.



Puntos de muestreos in situ de biomasa de pastizales: Región de Val Mazia (Italia)




Figura 4.6: Puntos de muestreos a campo (Val Mazia, Italia) [61]



Figura 4.7: Distribución de los pastizales en el área muestreada (Val Mazia, Italia)

4.3. Pre-procesamiento de imágenes satelitales

4.3.1. Pre-procesamiento de imágenes Sentinel-1

A través del software especializado SNAP se realizó el pre-procesamiento de cada imagen de radar lo cual es necesario para una mejor interpretación de la imagen antes de ser usada en una aplicación específica, reducir el ruido presente y darle un valor físico a cada píxel de la escena observada [47],[73].

En las imágenes adquiridas de S-1 se aplicaron los siguientes procesos de corrección:

Corrección radiométrica: involucra una serie de procedimientos para convertir los valores digitales de la imagen a valores de magnitudes físicas. De este modo los valores de píxel de las imágenes representan verdaderamente la retrodispersión del radar de la superficie reflectante [47]. La corrección radiométrica también se necesita para comparar las imágenes de SAR adquiridas de distintos sensores, o adquiridas del mismo sensor a diferentes horas, en modos distintos o procesadas por procesadores distintos [51].

Corrección geométrica: tiene como finalidad posicionar a nivel del terreno los píxeles de la

imagen y eliminar las distorsiones en la imagen [51]. En este trabajo para corregir la imagen a través del Software SNAP, se utilizó el Modelo Digital de Elevación (por sus siglas en inglés DEM) de auto descarga (SRTM 1sec) para el área de interés. La interpolación seleccionada por defecto es la bilineal y la proyección en el mapa UTM (WGS-84).

Existen otros procesos de corrección que dependerán del fenómeno bajo estudio y de los objetivos del analista. Para este trabajo, tal como se observa en el esquema (figura 4.8) el procedimiento de calibración aplicado a las imágenes S-1 son las siguientes: Apply Orbit File → Calibration → Speckle Filter → Thermal Noise Removal → Terrain Correction. Cabe aclarar que, dichas imágenes son productos de nivel 1 Ground Range Detected (GRD), las cuales incluyen en su procesamiento el Multilooking [69].

Considerando el orden de procesamiento como primera instancia se realizó la corrección de órbita precisa de la imagen seleccionando la pestaña en SNAP 'Apply Orbit File'. El archivo de la órbita contiene información sobre la posición y velocidad del satélite durante la adquisición de datos.

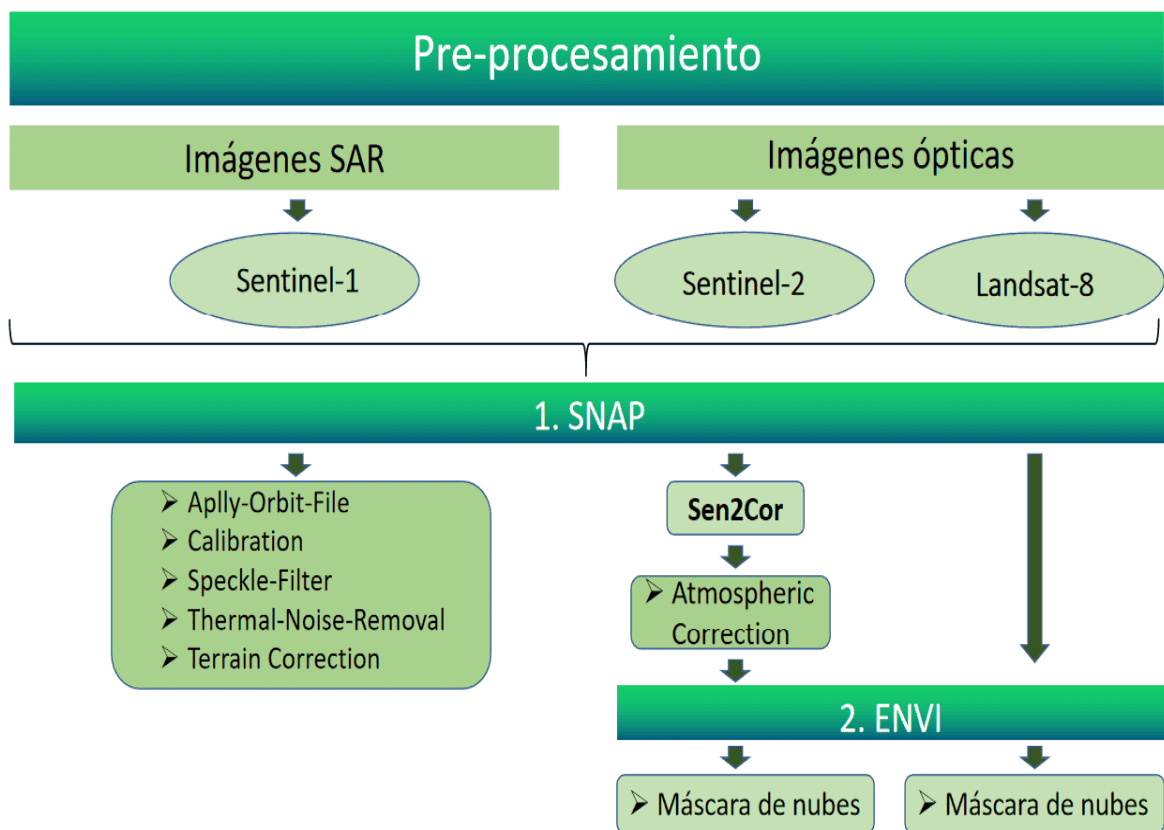


Figura 4.8: Esquema de pre-procesamiento de imágenes SAR y ópticas

El paso siguiente trata de la calibración radiométrica de la imagen como lo indican las pestañas de SNAP 'Radar → Radiometric → Calibration', para lograr que los valores de píxeles realmente representen el valor de la retrodispersión de la superficie reflectante. El software ejecutará las correcciones radiométricas de manera automática según los metadatos específicos de cada sensor. De esta manera se obtiene el primer paso para comenzar a interpretar y visualizar las imágenes [74].

Seguidamente se efectuó la reducción del moteado en la imagen siguiendo la selección de las pestañas en SNAP 'Radar → Speckle Filtering → Single Product Speckle Filter'. En este proceso se llevó a cabo un análisis de selección del tipo de filtro a utilizar en las imágenes

de radar. Para ello se escogió una imagen ya calibrada con los pasos previos descriptos de la zona de estudio correspondiente con la región de Entre Ríos, Argentina. Los filtros de reducción de moteado utilizados fueron el filtro 'Lee' y el 'Gamma Map' ambos con un tamaño de ventana de 3 x 3 píxeles, siendo seleccionados en ambos casos como los más adecuados para análisis de cultivos según [41] y [47] respectivamente.

En la siguiente figura 4.9 se detalla a la izquierda (a) la imagen S-1 original seleccionada, con fecha 2/4/2016 (modo de adquisición de la imagen (IW), tipo de procesamiento (GRDH) y polarización VH). Dicha imagen, no contiene ningún tipo de pre-procesamiento previo. En el medio (b) se visualiza la imagen pre-procesada con el filtro de moteado 'Lee' y la imagen de la derecha posee un filtro de moteado 'Gamma Map' (c).




Figura 4.9: Imágenes resultantes al aplicar los distintos filtros con SNAP

En las imágenes resultantes se compararon los estadísticos arrojados a través del software SNAP analizando los valores de la media (en potencia), desviación estándar y el número equivalente de looks (por sus siglas en inglés ENL) en aquellos píxeles de la imagen que representan los puntos georeferenciados donde se obtuvieron las muestras de biomasa de los pastizales en los sitios 1 y 2 (Entre Ríos, Argentina) arrojando los resultados plasmados en la siguiente tabla 4.1:

Tabla 4.1: Valores de media, desviación estándar y ENL según filtro de speckle utilizado

Sitio de estudio	Filtro de Speckle: Lee			Filtro de speckle: Gamma Map		
	Valor de la media	Desviación estándar	ENL	Valor de la media	Desviación estándar	ENL
'sitio 1'	0.011	0.0029	14.387	0.011	0.00293	14.094
'sitio 2'	0.009	0.00311	8.374	0.009	0.00312	8.321

El ENL se calcula a partir de la relación entre la media del área de interés en la imagen y la varianza de la misma al cuadrado. Como se observa en la tabla 4.1 el filtro de Lee posee menos desviación estándar y mayor ENL en ambos sitios de las imágenes analizadas con

respecto al filtro de Gamma Map. Conforme a estos resultados y considerando que mientras mayor sea el valor de ENL para un filtro, mayor será la eficiencia de mejorar la relación señal-moteado en áreas homogéneas, lo que significa que la calidad de imagen es mejor. Por lo tanto, Lee puede ser considerado el filtro más apropiado para el problema en estudio, por lo cual se definió aplicar dicho filtro en el procesamiento de las imágenes restantes.

Una vez aplicado el filtro de reducción de moteado se procede a seleccionar en la pestaña de SNAP 'Radar → Radiometric → Thermal Noise Removal' para realizar la reducción de ruido térmico. Aunque el proceso de eliminación de ruido sugerido por la ESA introdujo una gran mejora en la calidad de las imágenes, existen problemas restantes causados por una imperfección de los vectores de ruido, donde la contribución del ruido residual es significativa teniendo en cuenta una distribución de retrodispersión relativamente estrecha del canal de polarización cruzada [75].

Finalmente seleccionando las siguientes pestañas 'Radar → Geometric → Terrain Correction → Range Doppler Terrain Correction' el software realiza la corrección del terreno donde se decodifica la imagen corrigiendo las distorsiones geométricas SAR ya nombradas anteriormente (acortamiento, inversión y sombra). La geocodificación convierte una imagen de rango inclinado o geometría de rango de terreno en un sistema de coordenadas geográficas [74].

4.3.2. Pre-procesamiento de imágenes Sentinel-2

Como se observa en el esquema de la figura 4.8, el pre-procesamiento de las imágenes ópticas de Sentinel-2 se corresponde con los siguientes pasos: corrección atmosférica (SNAP) → máscara de nubes (ENVI).

Como primera instancia se realizó la corrección atmosférica de las imágenes ópticas con un nivel de tratamiento L1C utilizando la herramienta Sen2Cor dispuesta por la ESA y procesada con el software SNAP. A través de un 'script' por medio del software R-Studio se procedió a realizar dicho procesamiento de calibración a todo el dataset de imágenes ópticas disponibles.

Por medio de dicha corrección se pasa de un nivel de producto 1C o nivel de reflectividad TOA (por sus siglas en inglés Top of Atmosphere reflectance) a un nivel de reflectividad de superficie SR (por sus siglas en inglés Surface Reflectance) generando imágenes corregidas atmosféricamente denominados productos de nivel 2A. El Sen2Cor posee un algoritmo de corrección que trabaja sobre la banda 10 (cirrus) corrigiendo la presencia la bruma ligera de nubes, pero no así aquellas nubes de capa gruesa. Además, actúa sobre la banda 2 (azul), banda 4 (rojo) y la banda 12 (SWIR) para realizar una medición de transparencia atmosférica mediante el factor AOT (por sus siglas en inglés Aerosol Optical Thickness), eliminando el contenido de vapor de agua y corrigiendo según la superficie del terreno. Las imágenes resultantes son más nítidas y poseen valores de píxeles corregidos [49].

Las imágenes S-2 obtenidas fueron seleccionadas con el criterio de que posean un valor menor al 30% de cobertura nubosa, sin embargo, sobre aquellas imágenes donde la presencia de nubes se encontraba sobre el área de estudio fueron eliminadas a través de una máscara de nubes realizando una matemática de bandas en ENVI ('Basic tools → Band Math') dándoles valores 0 a las áreas con nubes y 1 a aquellas libres de nubes. Posteriormente, se aplicará sobre las bandas 3 y 4 que intervienen en la generación del índice NDVI, para que éste quede realizado con la corrección de nubes adecuada (ver sección 4.4.1).

A partir de dicha depuración en función de la cobertura de nubes, quedaron disponibles para el análisis en la zona de estudio ubicado en la región centro-sur de Entre Ríos (Argentina) 23 imágenes, siendo descartadas 11 que podemos revisar en el anexo B.

4.3.3. Pre-procesamiento de imágenes Landsat-8

En cuanto a las imágenes L-8 y a diferencia de las S-2, no es necesario realizar correcciones atmosféricas ya que las mismas fueron solicitadas con nivel de reflectividad de superficie, solo se les aplicó a las bandas espectrales de cada imagen un factor de conversión [47], que permite ajustar los valores de píxel a la escala de reflectancia (entre 0 y 1), dando una interpretación física a estos valores. Este procesamiento se realizó mediante el software ENVI seleccionando la pestaña Basic Tools → Band Math y aplicando la siguiente ecuación 4.1:

$$\text{Factor de escala} = \text{Banda espectral de la imagen} * (0,0001) \quad (4.1)$$

En aquellas imágenes L-8 donde la presencia de nubes se encontraban sobre los puntos muestreados, fueron eliminadas a través de una máscara de nubes que fue aplicada sobre imagen para evitar la obtención de datos erróneos (repitiendo el procedimiento antes mencionado para las S-2 a través de ENVI).

Una vez descartadas las 7 imágenes L-8 (ver anexo B) debido a la interferencia de nubes sobre el área de interés ubicado al sur de Entre Ríos (Argentina), quedaron disponibles 17 imágenes para ser usadas en este trabajo de investigación.

4.4. Procesamiento de imágenes satelitales

4.4.1. Procesamiento de imágenes ópticas (Sentinel-2 y Landsat-8)

Comenzando con el área de estudio en la región de Entre Ríos (Argentina) y replicando el procedimiento en la zona de Val Mazia (Italia), se realizó la compresión al formato 'zip' de las carpetas que contenían las imágenes S-2; luego, a través de un 'script' desarrollado con el lenguaje de programación Python, se calculó el índice NDVI y adicionalmente los índices SAVI y GNDVI para todas las imágenes, utilizando las bandas NIR y roja para los dos primeros índices y las bandas NIR y verde para el índice GNDVI, rescalando los productos a la misma resolución espacial de 10 metros (ver esquema de procedimiento general, figura 4.10). En cuanto a las imágenes de L-8, se calculó en las mismas el índice NDVI a partir de un 'script' generado con el lenguaje de programación R.

Seguidamente, mediante el software ENVI se extrajeron los valores de los índices de vegetación de S-2 y L-8, cuyos píxeles abarcan un área circular de 1.5 hectáreas y su centroide coincide con el punto geográfico donde se tomaron cada una de las muestras *in situ* de biomasa de los pastizales.

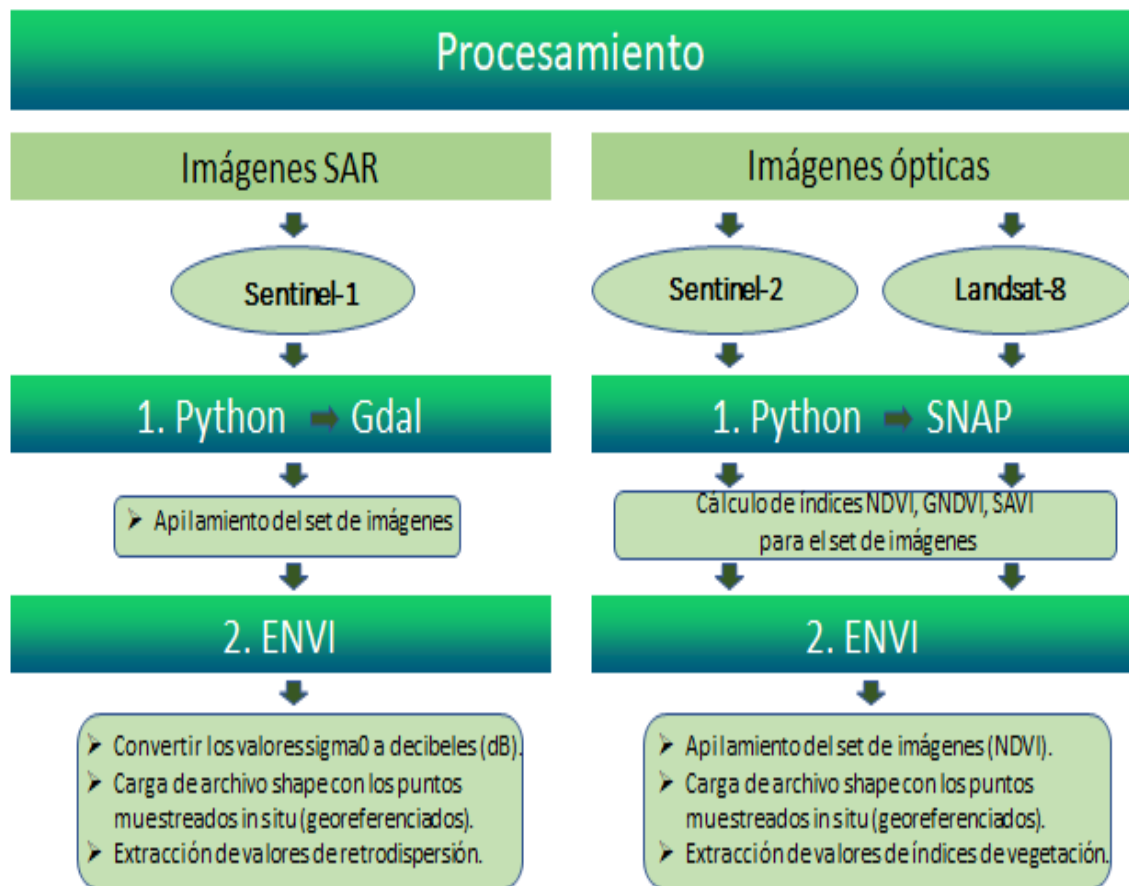


Figura 4.10: Esquema de procesamiento de las imágenes SAR y ópticas adquiridas

Para ello, se procedió al apilamiento del dataset de imágenes en el ENVI ('Basic tools → Layer Stacking') procurando mantener el orden cronológico de las mismas según su fecha para que coincida con aquellas fechas donde se tomaron las muestras *in situ* (ver figura 4.11). Se consideró dicho procedimiento para que todas las imágenes contengan el mismo sistema de georeferenciación y extensión permitiendo realizar una interpretación temporal del crecimiento de los pastizales, comparar la respuesta temporal de los índices de vegetación obtenidos en las imágenes S-2 y L-8, como así también compararlos con los valores de retrodispersión obtenidos para el mismo período y zona analizada por medio de las imágenes de radar S-1.

Al superponer los puntos georeferenciados de los sitios muestreados *in situ* de biomasa de los pastizales, a partir de la información vectorial (shape) permitió la extracción de los datos tanto ópticos como de radar.

A continuación, el archivo generado se exportó en formato ROI ('File → Export layers to ROI') para apilarse al dataset de imágenes previamente cargadas en el ENVI y finalmente extraer los valores de los índices de vegetación correspondientes a cada área y en cada imagen seleccionando las siguientes pestañas ('Tools → Region of Interest → ROI Tools' → Starts). El archivo obtenido se guardó en formato 'ASCII'.

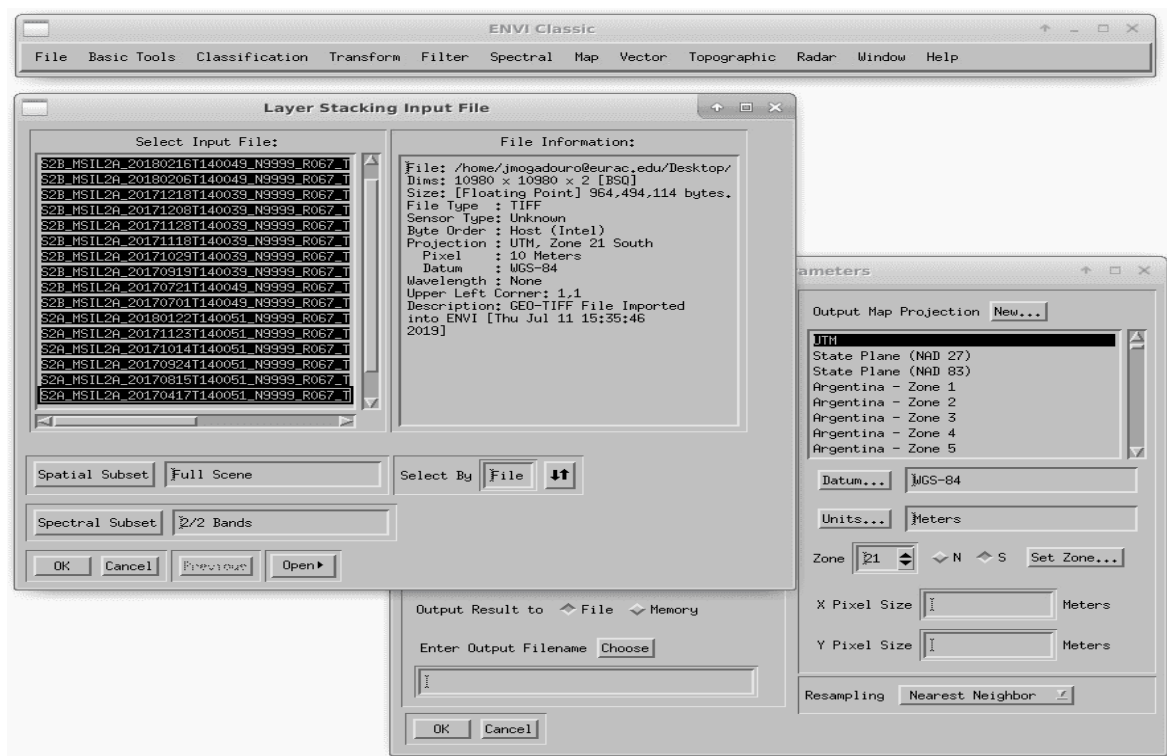


Figura 4.11: Ventana de apilamiento y georeferenciación de las imágenes a través de ENVI

4.4.2. Procesamiento de imágenes de radar (Sentinel-1)

Posteriormente al pre-procesamiento del dataset de las imágenes S-1 para la región de Entre Ríos, se procedió a realizar el apilamiento de las mismas a través del lenguaje de programación Python utilizando la librería 'Gdal' y luego con el comando 'Gdal-translate' se las transformó a formato 'tif' para que el software ENVI pueda leerlas (ver esquema de procedimiento general, figura 4.10). Seguidamente, se replicó el procedimiento efectuado con las imágenes ópticas, con el fin de extraer los valores del coeficiente de retrodispersión (σ^0) en las polarizaciones VH y VV (por separado) de las áreas de estudio (cuyos píxeles abarcan un área circular de 1.5 hectáreas y su centroide coincide con el punto geográfico donde se tomaron cada una de las muestras *in situ* de biomasa de los pastizales).

Cabe aclarar que, para una mejor interpretación de los datos se convirtieron los valores de σ^0 de las S-1 a decibelios (dB).

Este procedimiento se replicó para la extracción de los valores de retrodispersión (en las polarizaciones VH y VV) correspondientes con las áreas muestreadas *in situ* en la zona de estudio de Val Mazia (Italia).

4.5. Análisis de datos y variables disponibles que intervienen en el proceso de estimación de biomasa de los pastizales

En primera instancia de análisis se generaron gráficos multitemporales donde se visualiza la evolución de la biomasa de los pastizales (kgMS/ha) para todos los puntos muestreados *in situ* en las zonas de estudio de Argentina e Italia.

Región de Entre Ríos, Argentina La siguiente figura 4.12 describe las fechas de medición a campo de biomasa de los pastizales en los sitios de estudio que corresponden a la región centro-sur de Entre Ríos (Argentina). Las diferencias en los valores de biomasa pueden deberse a las condiciones edáficas heterogéneas, características fisiográficas, como así también a la diversa presión de pastoreo presente en ambos sitios de estudio.

- Sitio n° 1: muestras *in situ* de biomasa de los pastizales (MIBIOP) pertenecientes a un sector de suelos mixtos (con un ambiente único predominado por matas arbustivas de Chilca Baccharis), cuyo período de análisis contempla 3 años (desde diciembre del año 2015 a noviembre del año 2018).
- Sitio n° 2: muestras MIBIOP extraídas en áreas compuestas de suelos arenosos someros (zonas bajas, inundables, con menor cobertura) con predominancia de pastizales de baja altura que permanecen verdes más tiempo en periodos de sequía. El período de análisis se corresponde con el descripto para el sitio 1.




Figura 4.12: Evolución temporal de la biomasa de los pastizales en los sitios de estudio principales (región centro-sur de Entre Ríos, Argentina)

Región de Val Mazia, Italia

El área de estudio secundaria corresponde a la región de Val Mazia situada en el norte de Italia. El pequeño periodo de análisis de las muestras (MIBIOP) se extiende desde mayo del 2017 a octubre del mismo año (figura 4.13).




Figura 4.13: Evolución temporal de la biomasa de los pastizales en el sitio de estudio secundario (región de Val Mazia, Italia)

Esta información de campo conjuntamente con variables satelitales, tanto ópticas como radar, se utilizarán con el objeto de modelar la producción de biomasa (a partir de MIBIOP) en los lotes propuestos, por medio de modelos de Regresión Lineal Simple (SLR) y Regresión Lineal Múltiple (MLR). Para el procesamiento de los datos como así también, la verificación del cumplimiento de los supuestos de normalidad e independencia de los mismos, se utilizará el software estadístico R (ver en anexo D el 'script' desarrollado para la obtención de las regresiones y el análisis del cumplimiento de los supuestos). A partir de la información obtenida de las distintas variables, se seleccionarán aquellas que logren el mejor resultado (determinar la ecuación ajustada de la recta de mínimos cuadrados) y así, plantear las bases para la estimación de biomasa de los pastizales, como así también, la generación de un mapa de visualización de biomasa estimada.

El resultado del modelo (y el consecuente mapa) podría ser utilizado para el cálculo de carga animal instantánea, en función de la la biomasa estimada instantánea.

El análisis de regresión lineal tiene como objetivo principal identificar un modelo funcional que describa cómo varía la variable dependiente o de respuesta Y a medida que cambia la variable predictora o covariable X.

El modelo lineal simple (sólo vincula una variable predictora con Y) propone la siguiente ecuación 4.2 [76]:

$$Y = \beta_0 + \beta_1x + \varepsilon \quad (4.2)$$

- Y = Variable respuesta
- β_0 = Ordenada al origen de la recta de regresión
- β_1 = Pendiente de la recta de regresión
- ε = Término del error

Dicha ecuación interpreta que para cada valor de X , la correspondiente observación Y se compone del valor $\beta_0 + \beta_1 X$ más una cantidad ε , que puede ser positiva o negativa, y que da cuenta de que la relación entre X e Y no es exactamente lineal, sino que está expuesta a variaciones individuales que hacen que el par observado (X , Y) no se encuentre exactamente sobre la recta, sino cerca de ella [77].

Los métodos estadísticos, como los modelos de regresión, son las mejores herramientas para investigar cualquier relación entre variables dependientes e independientes cuando se dispone de pocos datos para la validación del modelo como sucede en este trabajo de investigación [78].

La verificación del cumplimiento de los supuestos de normalidad e independencia de cada variable usada en el modelo de SLR (4.3) se observa en el anexo E [79]:

$$\varepsilon_i \sim N(0; \sigma^2) \quad (4.3)$$

- Errores con distribución normal, independientes ($\varepsilon_i \sim N$)
- Homogeneidad de las varianzas y media 0 ($0; \sigma^2$)

4.5.1. Evaluación de la información óptica

4.5.1.1. Comparación de diferentes índices de vegetación

Región de Entre Ríos, Argentina

Una vez calibradas las imágenes ópticas (S-2), se procedió al cálculo y extracción de la información de los índices multispectrales NDVI, GNDVI y SAVI para la evaluación del estado de la vegetación.

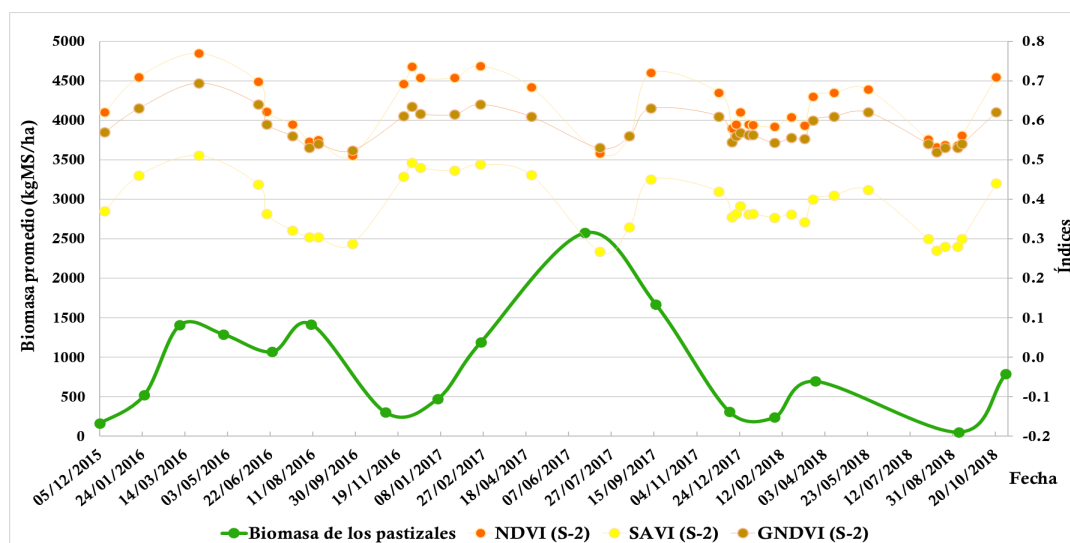
Dado que estos índices de vegetación exhiben valores de intensidad del verdor de la zona, y dan cuenta de la cantidad de vegetación presente en una superficie y su estado de salud o vigor vegetativo, se buscó establecer la relación entre los valores de NDVI, SAVI y GNDVI con respecto a las muestras MIBIOP tanto en el 'sitio 1' (figura 4.14 'a') como en el 'sitio 2' (figura 4.14 'b'). Cabe aclarar que en ambos sitios de estudio, se realizó un análisis temporal a partir de los datos de biomasa de los pastizales obtenidos *in situ* en relación con las variables satelitales.

Como se observa en la figura 4.14 todos los índices NDVI, SAVI y GNDVI poseen una tendencia similar en relación a los valores de las muestras MIBIOP (tanto en el 'sitio 1' como en el 'sitio 2'), observando valores más bajos para el índice SAVI con respecto a los obtenidos por medio de los índices NDVI y GNDVI. Esta diferencia podría deberse a que dicho índice tiene en cuenta además de la energía reflejada por la cobertura vegetal, la influencia de la reflectividad del suelo.

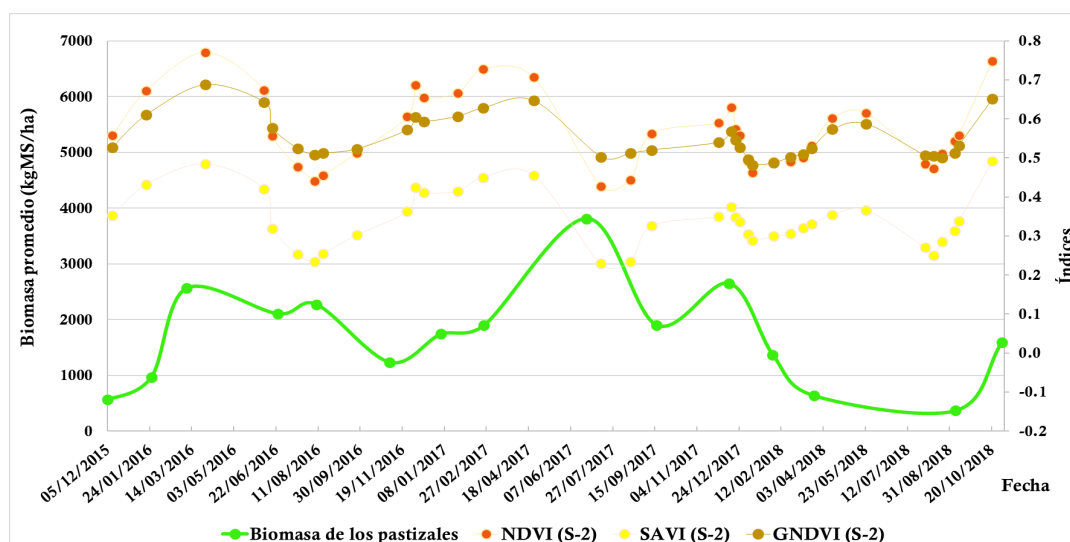
4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

Esta comparación se llevo a cabo para lograr detectar cuál de estos índices de vegetación se ajustan mejor en la estimación de biomasa de los pastizales. Para ello, se realizó un análisis de correlación entre éstos índices comparando la semejanza o diferencia de los valores medidos del vigor vegetal para todas las fechas que se adquirieron imágenes S-2 (ver anexo F).

Se obtuvo una fuerte correlación lineal entre el índice NDVI y SAVI [80] con un $R^2=0,96$ tanto para el 'sitio 1' como para el 'sitio 2', el cual es un resultado esperable considerando que ambos índices se construyen a partir de las mismas bandas espectrales y difieren sólo en constantes arbitrarias. En cuanto al análisis de correlación entre el NDVI y GNDVI, se computó también una muy buena correlación entre éstos índices [81], con un $R^2=0,95$ para el 'sitio 1' y un $R^2=0,90$ para el 'sitio 2' considerando la diferencia de una variante en el índice GNDVI respecto del NDVI empleando la información del canal verde en lugar del rojo.



(a)



(b)

Figura 4.14: Evolución temporal de la biomasa de los pastizales con respecto a los índices ópticos NDVI, SAVI y GNDVI para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

A partir de los resultados obtenidos de las correlaciones y considerando la similitud de respuesta de los distintos índices de vegetación en relación a las muestras de MIBIOP, se optó


4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

por el índice NDVI en ambos sitios de estudio para continuar con el análisis de estimación de biomasa de los pastizales. Cabe aclarar que la elección se sustenta en una nutrida cantidad de trabajos realizados a partir de dicho índice, lo cuál sirve de apoyo al momento de cotejar con los resultados obtenidos en el desarrollo de ésta tesis.

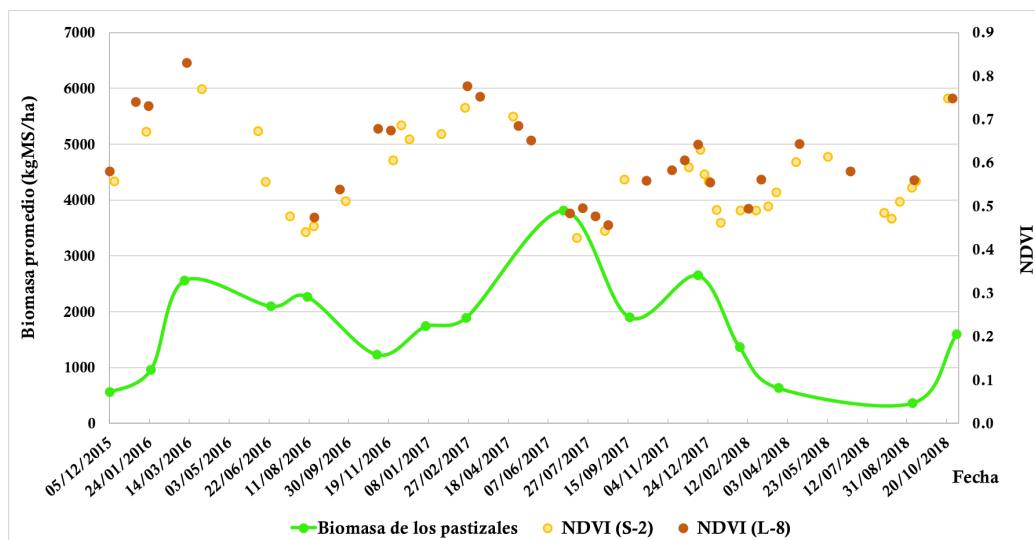
4.5.1.2. Relación entre la biomasa de los pastizales y el índice NDVI

Región de Entre Ríos, Argentina

El siguiente gráfico (ver figura 4.15), se corresponde al índice seleccionado para la comparación del NDVI (obtenido a partir de los sensores S-2 y L-8) y los datos de muestreos a campo en los sitios de estudio. El criterio de selección de fechas entre los datos de biomasa (MIBIOP) con respecto a los satelitales (NDVI) se corresponde a que los mismos se encuentren centrados en un período de +/- 7 días de manera que las variaciones en las condiciones de crecimiento de la vegetación sean las menores posibles [82].



(a)



(b)

Figura 4.15: Evolución temporal de la biomasa de los pastizales y el índice NDVI para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

Región de Val Mazia, Italia

Luego de realizar la extracción de los valores de NDVI (desarrollado en la sección 4.4.1) a partir de la información proveniente de los sensores ópticos (S-2 y L-8) para todos los puntos en el sitio de estudio secundario (Val Mazia), se generó un gráfico comparativo entre estos valores de NDVI en relación a la evolución temporal de la biomasa de los pastizales en la etapa de crecimiento de la vegetación (figura 4.16).




Figura 4.16: Evolución temporal de la biomasa de los pastizales y el índice NDVI (región de Val Mazia)

Repitiendo el procedimiento desarrollado sobre el área de estudio de Argentina, se realizó también, para el área de estudio en la región de Val Mazia, un análisis de SLR entre los valores de NDVI (obtenidos a partir de los sensores S-2 y L-8) y la muestras de MIBIOP, cuyos datos también fueron procesados con el software estadístico R (ver en anexo E el cumplimiento de los supuestos de normalidad e independencia de los datos).

4.5.2. Evaluación de la información SAR

4.5.2.1. Evolución de biomasa de los pastizales en relación a la retrodispersión (S-1)

Región de Entre Ríos, Argentina


La extracción de información SAR tiene por objeto correlacionar los valores de cada una de las bandas o ratios de bandas seleccionados con los valores de biomasa muestreados en los sitios de interés, para evaluar su relación a partir del modelo de regresión.

Luego de realizar la extracción de los valores de σ^0 (en Decibeles), a partir de los datos SAR de S-1 (desarrollado en la sección 4.4.2) en ambas áreas de estudio ubicadas la región centro-sur de Entre Ríos ('sitio 1' y 'sitio 2'), se crearon gráficos comparativos entre el σ^0 y la evolución temporal de la biomasa de los pastizales. En el anexo G se muestra dicha evolución en relación a todos valores de σ^0 obtenidos en el 'sitio 1', tanto en la polarización VV (a) como VH (b) como así también en el 'sitio 2', tanto en la polarización VV (c) como VH (d).


4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

Teniendo en cuenta que para lograr una mejor interpretación de la información de radar, en este estudio no se consideraron aquellas fechas donde se manifestara algún evento de lluvia en los dos días previos a las adquisiciones de las imágenes SAR, suponiendo que la cubierta vegetal y el suelo se encontrarían humedecidos debido a las lluvias pudiendo así alterar los valores de (σ^0) hasta dos días después del evento [83]. Los datos de las precipitaciones fueron obtenidos desde la página web de la estación agrometeorológica del INTA de Concepción del Uruguay ubicada al sur de la provincia de Entre Ríos (latitud -32,4881, longitud -58,3476) [84].

Los gráficos finales sin considerar dichos eventos de lluvias se detallan en la figura 4.17 para el 'sitio 1', donde se plasma la relación entre las muestras MIBIOP y los valores de σ^0 tanto en la polarización VV (figura a) como en la polarización VH (figura b). Los gráficos resultantes para el 'sitio 2' se observan en la figura 4.18, donde se distingue también el acuerdo entre las muestras MIBIOP y los valores de σ^0 tanto en la polarización VV (figura a) como en la polarización VH (figura b). Se observa en celeste para cada gráfico, la línea suavizada de la distribución del σ^0 , realizada por medio del método 'Mooving Average' utilizando los tres valores más recientes para calcular el promedio móvil (valor predeterminado).




(a)




(b)

Figura 4.17: Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b) sin considerar imágenes con eventos de lluvia hasta dos días previos a la adquisición de la misma ('sitio 1', Entre Ríos)

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES



(a)



(b)

Figura 4.18: Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b) sin considerar imágenes con eventos de lluvia hasta dos días previos a la adquisición de la misma ('sitio 2', Entre Ríos)

Al igual que en la sección anterior se consideraron aquellas fechas tanto de medición *in situ* como de adquisición de las imágenes que se encontrasen en un período no mayor a +/- 7 días entre ellos.

Asimismo, teniendo en cuenta lo mencionado previamente, se analizó también la relación existente entre el Ratio (VH/VV) y la evolución temporal de las MIBIOP, en el proceso de búsqueda del mejor estimador tanto en el 'sitio 1' como en el 'sitio 2'.

Dicha relación VH/VV puede reducir el efecto de doble rebote, como así también disminuir los errores asociados al sistema de adquisición (por ejemplo, debido a la estabilidad radio-métrica) o por causa de las variaciones de humedad del suelo, así como también los errores que resultan de la interacción suelo-vegetación. Además, puede aparecer como un indicador más estable en el tiempo en relación a las polarizaciones individuales de VV o VH [83].

Los valores de VH/VV (en Decibeles), se obtuvieron superponiendo los puntos georreferenciados de los sitios muestreados *in situ* de biomasa de los pastizales, junto a la capa vectorial (shape).

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

Una vez extraídos los valores de Ratio VH/VV para cada fecha y en ambos sitios de estudio, se los gráfico y comparó con las muestras MIBIOP. Fechas de muestreos a campo y datos de S-1 obtenidas entre enero del año 2016 y noviembre del año 2018.

Como se mencionó anteriormente, solo se consideraron en el análisis aquellas fechas de mediciones de MIBIOP y de adquisiciones de las imágenes SAR, que se encontrasen en un período no mayor a +/- 7 días entre ellos. Por lo cual, para poder estimar o vincular el tiempo existente entre dos fechas (en ambos sitios de estudio) se utilizó la función de Excel 'Linear Interpolation' (SRS1 Splines), donde se ingresa como imput al modelo los valores de Ratio VH/VV calculados y los valores correspondientes a las muestras MIBIOP que coincidan en sus fechas (ver tabla 4.2 correspondiente al 'sitio 1' y la tabla 4.3 correspondiente al 'sitio 2'). Obteniendo como datos de salida, los valores de Ratio VH/VV estimados para las fechas donde no se disponen datos en ambos sitios de estudio.

Tabla 4.2: Datos usados como entrada para la estimación del Ratio VH/VV en aquellas fechas de MIBIOP sin disponibilidad de datos para el 'sitio 1', Entre Ríos (Función: Linear Interpolation)

Fecha	Ratio VH/VV (S-1)	Biomasa de los pastizales (kgMS/ha) ('sitio 1')
28/1/2016	-5,40	519
4/11/2016	-6,26	303
4/1/2017	-5,57	472
24/2/2017	-5,49	1194
26/6/2017	-4,92	2575
19/9/2017	-5,43	1669
12/12/2017	-5,60	313
3/2/2018	-5,76	240
23/3/2018	-5,44	695
7/9/2018	-6,82	53
1/11/2018	-5,61	786


Tabla 4.3: Datos usados como entrada para la estimación del Ratio VH/VV en aquellas fechas de MIBIOP sin disponibilidad de datos para el 'sitio 2', Entre Ríos (Función: Linear Interpolation)

Fecha	Ratio VH/VV (S-1)	Biomasa de los pastizales (kgMS/ha) ('sitio 2')
28/1/2016	-5,01	966
4/11/2016	-6,97	1234
4/1/2017	-4,93	1741
24/2/2017	-5,46	1895
26/6/2017	-4,81	3811
19/9/2017	-4,60	1902
12/12/2017	-5,09	2650
3/2/2018	-4,53	1369
23/3/2018	-5,47	634
7/9/2018	-8,17	367
1/11/2018	-6,43	1594

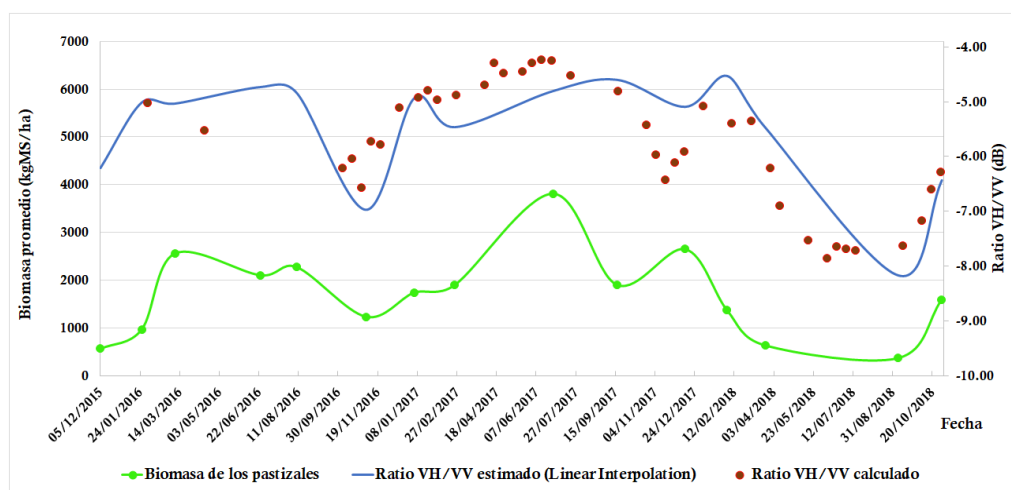
Los siguientes gráficos muestran la evolución de las muestras MIBIOP y los valores obtenidos del cálculo de Ratio VH/VV para aquellas fechas coincidentes entre enero del año 2016 y noviembre del año 2018 (ver puntos rojos en el gráfico), como así también, los valores estimados de Ratio VH/VV para el resto de las fechas de MIBIOP en ambos sitios de estudio

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

(ver línea azul en el gráfico). Correspondiendo la figura 4.19 (a) al 'sitio 1' y la figura 4.19 (b) al 'sitio 2'.



(a)



(b)


Figura 4.19: Evolución temporal de la biomasa de los pastizales y los valores calculados y estimados de Ratio VH/VV para el 'sitio 1' (a) y 'sitio 2' (b), Entre Ríos

Región de Val Mazia, Italia


Un vez obtenidos los valores del σ^0 de las imágenes SAR (S-1) para las áreas de interés en Argentina a través del software ENVI, se replicó dicho procedimiento para el área de estudio en la región de Val Mazia (Italia) (cálculos desarrollados en la sección 4.4.2). En el anexo H se detallan los gráficos que exponen la evolución de las muestras MIBIOP en relación a todos valores del σ^0 calculados en la polarización VV ('a') y VH ('b').

Conservando solo aquellos valores del σ^0 alejados temporalmente de precipitaciones que pudieran influenciarlos (presentes hasta dos días previos a las adquisiciones de las imágenes SAR), se detallan en la figura 4.20 los gráficos resultantes de la relación entre los valores de σ^0 tanto en la polarización VV (figura a) como en la polarización VH (figura b) y las muestras MIBIOP. Se observa en celeste para cada gráfico, la línea suavizada de la distribución del σ^0 , realizada por medio del método 'Mooving Average' utilizando los tres valores más recientes para calcular el promedio móvil (valor predeterminado).

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES



(a)



(b)

Figura 4.20: Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en polarización VH (a) y polarización VV (b), sin considerar imágenes con eventos de lluvias (Val Mazia)

Al igual que en la sección anterior se consideraron aquellas fechas tanto de medición *in situ* como de valores de retrodispersión que se encontrasen en un período no mayor a +/- 7 días entre ellos.

Para poder corroborar la presencia de eventos de lluvia en las fechas muestreadas, se localizó la estación agrometeorológica mas cercana al área de estudio (región de Val Mazia), desde la página web Open Data del Súd Tirol Alto Adige [85]. Extrayendo desde dicho portal los valores de precipitaciones correspondientes con el año 2017.

Finalmente, también se replicó el procedimiento realizado en el área de estudio de Argentina (desarrollado en la sección 4.5.2.1), para la obtención de los valores de Ratio (VH/VV) y cuantificar la respuesta estimativa de la biomasa de los pastizales en dicha área de interés en Val Mazia.

La siguiente figura 4.21 plasma la evolución de las muestras MIBIOP (desde mayo a octubre del año 2017) y los valores calculados (ver puntos naranjas en el gráfico) y estimados (línea celeste) de Ratio VH/VV. A partir de los cuales se procederá con el análisis del modelo de regresión lineal.

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES




Figura 4.21: Evolución temporal de la biomasa de los pastizales y los valores calculados y estimados de Ratio VH/VV (Val Mazia)

4.5.2.2. Análisis de precipitaciones en función a la retrodispersión SAR

Región de Entre Ríos, Argentina

Para poder interpretar mejor el motivo de la variación del coeficiente de retrodispersión de la cubierta de los pastizales, se analizó también la influencia de las precipitaciones de acuerdo con su momento e intensidad sobre ambos sitios de estudio (región centro-sur de Entre Ríos, Argentina).

En el siguiente gráfico 4.22 se visualizan los eventos de precipitaciones en relación a la evolución de biomasa de los pastizales en ambos sitios de estudio. El período de distribución de las lluvias considerado, inicia en el mes de diciembre del año 2015 hasta el mes de noviembre del año 2018, concordando con el período de obtención de muestras *in situ* de pastizales.





Figura 4.22: Ocurrencia de lluvias y evolución temporal de la biomasa de los pastizales en las áreas de interés (sitio 1 y sitio 2, Entre Ríos)

4.5 ANÁLISIS DE DATOS Y VARIABLES DISPONIBLES QUE INTERVIENEN EN EL PROCESO DE ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES


Teniendo en cuenta la influencia de las precipitaciones en la producción de materia seca de los pastizales, se consideró plasmar la respuesta del σ^0 ante los eventos de lluvia previos o durante la adquisición de todas las imágenes de radar de S-1 (desde diciembre del 2015 a noviembre del 2018).

Para ello, se graficó la respuesta del σ^0 en ambas polarizaciones (VV y VH) y en ambas áreas de estudio. Donde se visualiza en la figura 4.23 'a' la variación del σ^0 para el 'sitio 1' y en la figura 4.23 'b' el cambio de σ^0 para el 'sitio 2', contrapuestas con los eventos de lluvias.

Se observa en ambos sitios de estudio, un aumento del σ^0 (hasta 4 Decibeles [86]) en ambas polarizaciones (VV y VH) al manifestarse algún evento de lluvia antes (hasta 2 días previos) o durante la fecha de adquisición de la imagen S-1 [83]. Por lo cuál, debido a la presencia de éstos picos de variación del σ^0 en respuesta a los eventos de lluvias, que podrían afectar negativamente la estimación de biomasa de los pastizales, se depuraron las fechas que coincidían con precipitaciones en la ventana temporal de dicho análisis (tal como se mencionó en la sección 4.5.2.1).



(a)



(b)

Figura 4.23: Respuesta del coeficiente de retrodispersión (polarización VV y VH) en relación a eventos de lluvia ocurridos en el 'sitio 1' (a) y 'sitio 2' (b) (Entre Ríos)

4.6. Aplicación de un modelo de Regresión Lineal Múltiple para la estimación de biomasa de los pastizales

Región de Entre Ríos, Argentina

Después de sistematizar y depurar todas las variables que componen al modelo de regresión simple, se realizó la integración del conjunto de datos ópticos y SAR utilizando un modelo de (MLR), aplicado en ambos sitios de estudio en Entre Ríos ('sitio 1' y 'sitio 2').

El modelo MLR se utiliza para explicar el comportamiento de una variable a través de variables predictoras adicionales, para proporcionar predicciones más precisas y colaborar en la cuantificación del vínculo entre ellas.

El modelo MLR (vincula varias variables predictoras con Y) propone la siguiente ecuación 4.4 [76]:

$$Y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \varepsilon \quad (4.4)$$

- Y = Variable respuesta
- β_0 = Ordenada al origen de la recta de regresión
- β_1 = Pendiente de la variable x_1
- x_1 = Variable regresora x_1
- β_2 = Pendiente de la variable x_2
- x_2 = Variable regresora x_2
- β_3 = Pendiente de la variable x_3
- x_3 = Variable regresora x_3
- ε = Término del error

Para este trabajo de investigación las variables regresoras o predictoras se corresponden con los datos integrados de NDVI resultantes de la combinación de información derivada de los sensores S-2 y L-8, los valores del σ^0 en la polarización VH y los valores de Ratio VH/VV obtenidos a partir de las imágenes S-1.

Cabe aclarar que no se consideraron para dicho análisis los valores del σ^0 en la polarización VV (S-1), teniendo en cuenta que se seleccionaron solo aquellas variables que mejor se correlacionaron con respecto a las MIBIOP en el proceso estimativo de biomasa de los pastizales.

Al comparar los valores del índice NDVI entre fechas próximas para ambos sensores ópticos (S-2 y L-8), extraídos sobre la misma área de estudio del 'sitio 1', se obtuvo una elevada correlación entre los mismos con un $R^2= 0.93$. Como así también, los valores promedio de NDVI obtenidos en la extensión del 'sitio 2' demostrando una elevada correlación entre ambos sensores ($R^2= 0.94$) (ver anexo I). A partir de los resultados obtenidos, se optó combinar la información proveniente de los sensores ópticos de S-2 con L-8 permitiendo cubrir los batches generados en las fechas donde la presencia de nubes restringe el uso de los mismos. Ésta sinergia de datos ópticos para el cálculo del MLR, ayuda a analizar qué tan bien estas me-

4.6 APLICACIÓN DE UN MODELO DE REGRESIÓN LINEAL MÚLTIPLE PARA LA ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

didadas conjuntas son adecuadas para mejorar la precisión de la predicción. Además, permite superar la diferencia en la resolución espacial entre ambos sensores simplemente extrayendo los valores promedio (NDVI) de los píxeles de la misma área de interés, sin la necesidad del remuestreo espacial, que potencialmente tiene efectos secundarios no deseados en la calidad de los resultados [87].

En este caso, al igual que en las secciones anteriores, se seleccionaron aquellas fechas que se encontrasen en un período no mayor a +/- 7 días entre ellos (desde diciembre del año 2015 hasta noviembre del año 2018) extrayendo la siguiente información, datos de campo (MIBIOP), valores de NDVI (S-2 y L-8), como así también, σ^0 en la polarización VH y Ratio VH/VV. En este apartado tampoco se consideraron aquellas fechas donde se manifestara algún evento de lluvia en los dos días previos a las adquisiciones de las imágenes SAR.

A través de un 'script' desarrollado con el lenguaje de programación R (ver en anexo D), se realizó el procesamiento de los datos del modelo MLR y la verificación del cumplimiento de los supuestos de normalidad e independencia de los mismos se plasman en el anexo E.

A continuación se expresan los cumplimientos de dichos supuestos para el modelo MLR (4.5):

$$\varepsilon_i \sim N(0; \sigma^2) \quad (4.5)$$

- Errores con distribución normal, independientes ($\varepsilon_i \sim N$)
- Homogeneidad de las varianzas y media 0 ($0; \sigma^2$)
- No existe correlación entre cada una de las variables predictoras 'Xi'

En las siguientes tablas se visualizan las variables predictoras independientes (NDVI, σ^0 (VH), Ratio (VH/VV)) utilizadas en el modelo MLR para la estimación de biomasa de los pastizales (variable dependiente) en el 'sitio 1' (tabla 4.4 'a') y en el 'sitio 2' (tabla 4.5 'b').

Una vez organizados los datos obtenidos para los sitios de estudio en tablas separadas, se corrió el modelo MLR para cada sitio, mediante el lenguaje de programación R.

Tabla 4.4: Datos utilizados como entrada en el modelo MLR para el 'sitio 1' (Entre Ríos, Argentina)

Fecha	Biomasa de los pastizales (kgMS/ha) ('sitio 1')	σ^0 VH (S-1)	Ratio VH/VV	Índice NDVI (S-2 y L-8)
26/1/2016	519	-20.32	-5.40	0.72
4/11/2016	303	-19.60	-6.26	0.68
24/2/2017	1194	-19.82	-5.49	0.77
28/6/2017	2575	-18.35	-4.92	0.58
17/9/2017	1669	-18.38	-5.43	0.72
12/12/2017	313	-19.72	-5.60	0.60
3/2/2018	240	-20.62	-5.76	0.58
23/3/2018	695	-19.55	-5.44	0.66
7/9/2018	53	-20.11	-6.82	0.56
1/11/2018	786	-19.39	-5.61	0.71

4.6 APLICACIÓN DE UN MODELO DE REGRESIÓN LINEAL MÚLTIPLE PARA LA ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

Tabla 4.5: Datos utilizados como entrada en el modelo MLR para el 'sitio 2' (Entre Ríos, Argentina)

Fecha	Biomasa de los pastizales (kgMS/ha) ('sitio 2')	σ^0 VH (S-1)	Ratio VH/VV	Índice NDVI (S-2 y L-8)
26/1/2016	966	-19.86	-5.01	0.67
4/11/2016	1234	-20.70	-6.97	0.68
24/2/2017	1895	-20.26	-5.46	0.75
28/6/2017	3811	-19.00	-4.81	0.48
17/9/2017	1902	-18.34	-4.60	0.56
12/12/2017	2650	-19.64	-5.09	0.64
3/2/2018	1369	-20.38	-4.53	0.49
23/3/2018	634	-21.67	-5.47	0.53
7/9/2018	367	-20.70	-8.17	0.54
1/11/2018	1594	-19.40	-6.43	0.70

Región de Val Mazia, Italia

Al igual que en el área de estudio principal de Entre Ríos (Argentina), también se utilizó el modelo MLR para el área de interés secundaria en la región de Val Mazia (Italia). Por lo cuál, se utilizaron como variables predictivas de biomasa de los pastizales, los valores de NDVI (provenientes de la sinergia entre las imágenes ópticas de S-2 y L-8) junto a los valores de retrodispersión en la polarización VH y VV, extraídos de las imágenes de radar S-1 (entre mayo y octubre del año 2017).

En este apartado, se descartaron los valores provenientes del Ratio (VH/VV) debido a la falta de correlación con respecto a las MIBIOP. Cabe aclarar que tampoco se consideraron aquellas fechas donde se manifestara algún evento de lluvia en los dos días previos a las adquisiciones de las imágenes SAR.

En la siguiente tabla (4.6) se visualizan las variables predictoras independientes que manifestaron mejor correlación individual en relación a las MIBIOP (NDVI, σ^0 (VH) y σ^0 (VV)) utilizadas en el modelo MLR para la estimación de biomasa de los pastizales (variable dependiente).

Los datos organizados en dicha tabla fueron utilizados para correr el modelo MLR mediante el software Excel, seleccionando en el mismo las siguientes pestañas (Data → Data Analysis → Regression).

Tabla 4.6: Datos utilizados como entrada en el modelo MLR (región de Val Mazia, Italia)

Fecha	Biomasa de los pastizales (kgMS/ha) (Val Mazia)	σ^0 VH (S-1)	σ^0 VV (S-1)	Índice NDVI (S-2 y L-8)
26/5/2017	279	-19.12	-11.50	0.48
2/6/2017	1549	-16.45	-8.73	0.59
16/6/2017	990	-17.00	-10.50	0.61
23/6/2017	2080	-15.92	-8.00	0.60
28/6/2017	1890	-16.02	-7.00	0.63
15/7/2017	1267	-16.35	-6.98	0.57
7/8/2017	1460	-16.85	-7.62	0.64
21/8/2017	1788	-16.87	-5.64	0.62
14/9/2017	1316	-17.80	-7.32	0.63
11/10/2017	1266	-17.70	-8.38	0.56

4.7. Generación del mapa de biomasa de los pastizales estimado a partir del modelo MLR

Región de Entre Ríos, Argentina

Una vez obtenidos los resultados de las correlaciones individuales e integradas entre los datos provenientes de las imágenes ópticas y de radar en relación a las MIBIOP (para ambos sitios de estudio principales en la región centro-sur de Entre Ríos), se generará un mapa de visualización de biomasa de los pastizales estimada a partir de las variables seleccionadas del modelo de regresión.

En función de los resultados obtenidos en el análisis de regresión lineal desarrollado en las secciones anteriores, se escogió el modelo MLR aplicado sobre el 'sitio 1' para modelar la biomasa de los pastizales. Dicho sitio de estudio obtuvo un mejor ajuste a partir del estadístico R^2 con todas las variables analizadas, y un error cuadrático medio (RMSE) menor en relación al 'sitio 2'.

Para generar el mapa estimativo de biomasa se seleccionó una imagen óptica (S-2) y otra de radar (S-1) en la misma fecha (15/12/2017) y área de interés. Seguidamente, dichas imágenes se cargaron en el software ENVI y fueron recortadas en la zona de estudio de Entre Ríos, que incluye el 'sitio 1' y su entorno. Se realizó el apilamiento de las imágenes S-1 y S-2 y por medio de la expresión 'matemática de bandas' se insertaron los coeficientes de regresión de las variables usadas en el modelo MLR (ecuación ajustada de la recta de mínimos cuadrados). Dichas variables NDVI, σ^0 en la polarización VH y Ratio VH/VV, fueron las que mejor se correlacionaron con las MIBIOP en el proceso estimativo de biomasa de los pastizales. De esta manera, la imagen resultante plasma los valores estimados a partir del modelo MLR de biomasa de los pastizales correspondiente con el 'sitio 1' de estudio y su entorno.

Dicha información podría ser de utilidad para un usuario final (productor agropecuario) para el cálculo de carga animal instantánea (cantidad de animales que pastorean un potrero/lote de determinada superficie en un momento o instante dado), en función de la biomasa estimada instantánea.

Fórmula para el cálculo de carga animal instantánea (4.6) [88]:

$$\text{Carga animal instantánea (vaca/ha)} = \frac{\text{MSi}}{\text{PV} * \text{NOF}} * 100 \quad (4.6)$$

MSi → Oferta de biomasa en un momento o instante dado (kgMS/ha)

PV → Peso vivo de un animal

NOF → Nivel de oferta forrajero deseado en % del PV en un momento o instante dado

4.8. Identificación y mapeo de áreas con pastizales en la región centro-norte de Entre Ríos utilizando imágenes ópticas y de radar

En esta sección se describe la experiencia de clasificación de pastizales en la región centro-norte de Entre Ríos, Argentina.

El empleo de la teledetección en la clasificación de imágenes cumple con la intención de categorizar todos los píxeles de una imagen en diversas clases temáticas, de tal manera que los píxeles de la misma clase tengan propiedades similares. Esta información categorizada se utiliza para poder describir el territorio, sus características fisiográficas y los usos del suelo que predominan, información que de otra manera sería muy difícil de recabar. Los métodos de clasificación se dividen usualmente en dos tipos, supervisados y no supervisados.

En la metodología de clasificación supervisada (ClaSup), el usuario selecciona y delimita los grupos de píxeles homogéneos en una imagen, que representan los patrones de diferentes clases temáticas, generando campos o áreas de entrenamiento [89]. Se trata de áreas donde se conoce a priori la clase a la que pertenecen, lo cuál permitirá generar una firma espectral (imagen óptica) o polarimétrica (imagen radar) característica para cada una de las clases [90].

En la clasificación no supervisada (ClaNoSup), la agrupación de píxeles se basa en datos sin etiquetar [91], donde el analista no interviene en el proceso de clasificación (sólo especifica un número de regiones o clases).

En el presente trabajo, el área de estudio se encuentra dentro del ejido del departamento Feliciano cubriendo una superficie de 1517 Km². Se dispuso de datos *in situ* de biomasa de los pastizales, cuyas muestras se recolectaron en diferentes puntos de la superficie analizada durante el año 2017, las cuáles fueron utilizadas para validar áreas con pastizales. Las imágenes satelitales se seleccionaron en una ventana temporal entre abril y septiembre del año 2017.

Se procedió a través del software ENVI a la selección de los algoritmos de clasificación de las imágenes, optando por el algoritmo de clasificación supervisado (ClaSup) de Mahalanobis Distance, y el algoritmo de clasificación no supervisado (ClaNoSup) de K-Means, aplicados sobre un conjunto de imágenes ópticas (S-2) y de radar (S-1).

Se consideró para el análisis de desempeño del algoritmo de ClaSup (por medio de la matriz de confusión), una relación de 70/30 en las áreas seleccionadas (70 % áreas de entrenamiento y 30 % áreas de validación) [92] [18].

Mahalanobis Distance es un clasificador de distancia, que utiliza estadísticas para cada clase. Es similar a la clasificación de máxima verosimilitud, pero supone que todas las covarianzas de clases son iguales y, por lo tanto, es un método más rápido. Este clasificador tiene en cuenta la variabilidad en la clase de referencia y la información compartida entre las bandas (correspondiente con cada imagen del conjunto), sin depender de una escala única de medida. Todos los píxeles se clasifican en la clase de referencia más cercana a menos que se especifique un umbral de distancia, en cuyo caso algunos píxeles pueden no clasificarse si no alcanzan dicho umbral [93].

La clasificación no supervisada de K-Means calcula las medias de las clases iniciales distribuidas uniformemente en el espacio de datos, luego agrupa de forma iterativa los píxeles

en la clase más cercana utilizando una técnica de distancia mínima. Cada iteración recalcula las medias de clase y reclasifica los píxeles con respecto a las nuevas medias hasta que se logre una separación espectral óptima. Todos los píxeles se clasifican a la clase más cercana a menos que se especifique una desviación estándar o un umbral de distancia, en cuyo caso algunos píxeles pueden no clasificarse si no cumplen con los criterios seleccionados. Este proceso finaliza cuando se alcanza un cierto umbral de cambio o se obtiene el número máximo de iteraciones. [93].

4.8.1. Clasificación con imágenes ópticas (S-2)

Se procedió a realizar la selección y el apilamiento de 5 imágenes ópticas (S-2) (ver listado en anexo J), las cuales ya fueron previamente calibradas y procesadas para la obtención del índice NDVI en las mismas (desarrollado en la sección 4.4.1). El apilamiento permite correlacionar la información contenida en el píxel tanto en el tiempo y en el espacio permitiendo a partir de ello determinar como es la dinámica del comportamiento de una zona homogénea, aportando más información al proceso de clasificación.

Seguidamente, se procedió a delimitar las regiones de interés (por sus siglas en inglés ROIs), donde los píxeles seleccionados (que conforman cada ROI) se corresponden con las áreas muestreadas *in situ* de biomasa de los pastizales (MIBIOP) en la región centro-norte de Entre Ríos, Argentina.

Para la realización de ROIs sobre aquellas coberturas ubicadas en otras áreas (sin pastizales) como por ejemplo: sectores con monte nativo, áreas destinadas a la producción de arroz y otras coberturas (cultivos de invierno, suelo desnudo, lotes en barbecho), se tomó como base una imagen de S-2 (10 metros/píxel de resolución) de la misma área de estudio con fecha 28/07/2017. Se generó en dicha imagen una composición RGB combinando las bandas de color natural (B4-B3-B2), cuya imagen resultante, permite comparar y contrastar con los resultados del índice NDVI en aquellas áreas sin vegetación (bajos valores de NDVI), confrontado con altos valores de NDVI detectados en las áreas con presencia de pastizales y monte nativo, considerando una respuesta media-alta del índice de verdor para la fecha en la cual fue seleccionada la imagen S-2.

Para una mejor identificación de áreas agrícolas se combinaron las bandas (B11, B8A, B2), resaltando la vegetación densa que aparece como verde oscuro en la imagen (cultivos de crecimiento otoño-invernal).

Teniendo en cuenta que gran parte del área de estudio abarca el departamento de Feliciano, y que en el mismo la actividad arrocera es muy importante, se identificaron las superficies destinadas a la producción de dicho cultivo, como así también, las represas-lagunas que las abastecen [94]. Dicha información se visualiza en el siguiente mapa (ver figura 4.24).

Por último, se realizó una comparación visual de las diferentes coberturas presentes en la zona de estudio, consultando en la plataforma web 'Land Cover View' el mapa de clasificación de la cubierta terrestre producido por Copernicus Global Land Service, como así también, se consideró como información adicional el aporte de imágenes panorámicas que proporciona la herramienta de Google "Street View" permitiendo hacer una evaluación visual de aquellas coberturas que se encuentran en cercanía a una ruta (figura 4.25).

4.8 IDENTIFICACIÓN Y MAPEO DE ÁREAS CON PASTIZALES EN LA REGIÓN CENTRO-NORTE DE ENTRE RÍOS UTILIZANDO IMÁGENES ÓPTICAS Y DE RADAR

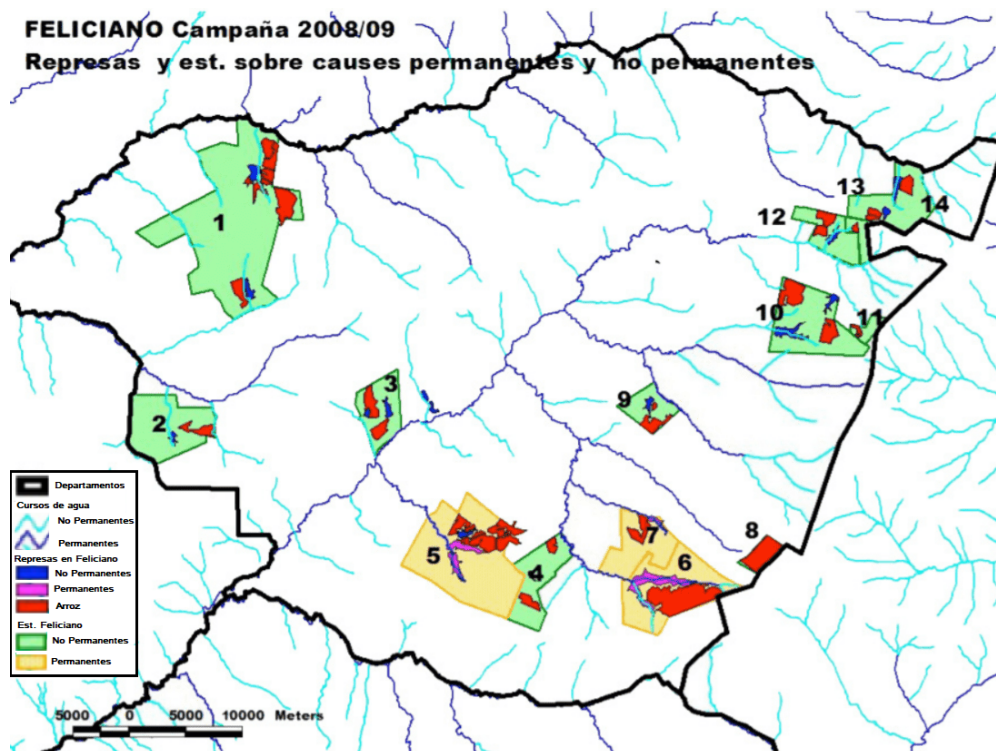


Figura 4.24: Mapa de áreas destinadas a la producción de arroz (2008/2009) y las represas-lagunas que abastecen a las mismas (Departamento de Feliciano, Entre Ríos) [94]




Figura 4.25: Capturas de Google 'Street View', correspondientes a diferentes coberturas identificadas en la zona de estudio (región centro-norte de Entre Ríos)

4.8 IDENTIFICACIÓN Y MAPEO DE ÁREAS CON PASTIZALES EN LA REGIÓN CENTRO-NORTE DE ENTRE RÍOS UTILIZANDO IMÁGENES ÓPTICAS Y DE RADAR

Una vez creadas las ROIs sobre las coberturas de interés (pastizales, monte nativo, cultivos de arroz y otras coberturas), se procedió a través del software QGIS a extraer aleatoriamente dentro del conjunto de ROIs para cada clase, aquellas destinadas al entrenamiento y validación de los clasificadores en relación 70/30 respectivamente, seleccionando las siguientes pestañas: Procesos → Caja de herramientas → Selección vectorial → Extracción aleatoria. En la siguiente figura 4.26 se observan en distinta coloración las ROIs obtenidas sobre diferentes coberturas y el detalle de la máscara creada en dicha área de estudio, con el propósito de que el clasificador no considere aquellas áreas indeseadas como cuerpos de agua, vías de escurrimiento y la ciudad de San José de Feliciano.

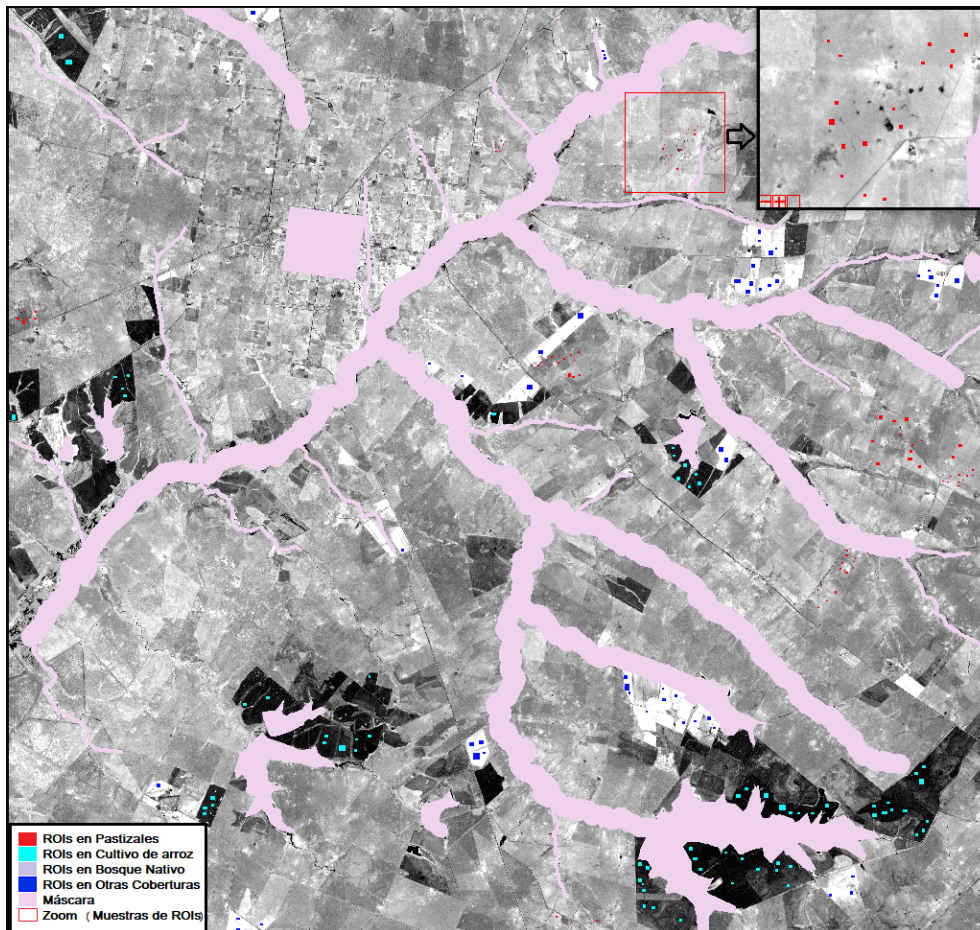


Figura 4.26: Visualización de las ROIs obtenidas en diferentes coberturas y la máscara de áreas indeseadas realizada sobre una imagen S-2 (región centro-norte de Entre Ríos)

Seguidamente, se verificó si dichas ROIs son suficientemente iguales entre si para ROIs de la misma clase y lo suficientemente independientes y diferenciables entre si para ROIs de clases distintas. Para ello, se cargaron en el ENVI las ROIs ya aleatorizadas y se seleccionaron las siguientes pestañas: → ROI Tools → Options → Compute ROI separability (ésta última contiene información de la separación espectral de las ROIs realizadas).

Los valores obtenidos informan las medidas de separabilidad de Jeffries-Matusita y de divergencia transformada (cuyos valores varían entre 0.0 y 2.0). Para valores de ROIs que superan 1.9 indican que los pares de ROIs tienen muy buena separabilidad. Si el valor de separabilidad es inferior a 1.0, entonces es más probable que se trate de ROIs correspondientes a la misma clase de superficie [95].

Una vez realizado el cálculo de separabilidad de las ROIs, se generó un cuadro de diálogo

4.8 IDENTIFICACIÓN Y MAPEO DE ÁREAS CON PASTIZALES EN LA REGIÓN CENTRO-NORTE DE ENTRE RÍOS UTILIZANDO IMÁGENES ÓPTICAS Y DE RADAR

donde se expone al final del informe, la capacidad de separación de pares de ROIs (distancia de Jeffries-Matusita) enumerados desde el par menos separable hasta el más separable (figura 4.27). El informe se guarda en un archivo con formato ASCII.

Los resultados indican que las clases (entrenamiento y validación) de 'Pastizales' son similares entre si (0.086), seguidas por las clases de 'Monte Nativo' (0.252), 'Arroz' (0.32) y 'Otras Coberturas' (0.483), las cuales poseen muy buena homogeneidad entre sus clases.

Analizando la separabilidad entre las clases de las diferentes coberturas, los resultados fueron prominentes siendo superiores a 1.94 (elevada separación espectral entre las clases).

```
Pair Separation (least to most);
Pastizales_entrenamiento [Red1] 2667 points and Pastizales_validación [Red2] 1150 points - 0.08698874
MonteNativo_entrenamiento [Magenta1] 2160 points and MonteNativo_validación [Magenta2] 642 points - 0.25205312
Arroz_entrenamiento [Cyan1] 9525 points and Arroz_validación [Cyan2] 3176 points - 0.32062101
OtrasCoberturas_entrenamiento [Blue1] 7637 points and OtrasCoberturas_validación [Blue2] 3136 points - 0.48323644
MonteNativo_validación [Magenta2] 642 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.94167666
MonteNativo_entrenamiento [Magenta1] 2160 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.94501251
MonteNativo_validación [Magenta2] 642 points and Pastizales_entrenamiento [Red1] 2667 points - 1.95379660
MonteNativo_validación [Magenta2] 642 points and Pastizales_validación [Red2] 1150 points - 1.96641916
MonteNativo_entrenamiento [Magenta1] 2160 points and Pastizales_entrenamiento [Red1] 2667 points - 1.96828469
MonteNativo_entrenamiento [Magenta1] 2160 points and Pastizales_validación [Red2] 1150 points - 1.97427920
MonteNativo_validación [Magenta2] 642 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.99390166
MonteNativo_entrenamiento [Magenta1] 2160 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.99483447
OtrasCoberturas_validación [Blue2] 3136 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99895176
Arroz_validación [Cyan2] 3176 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99919036
Arroz_validación [Cyan2] 3176 points and Pastizales_validación [Red2] 1150 points - 1.99933883
OtrasCoberturas_validación [Blue2] 3136 points and Pastizales_validación [Red2] 1150 points - 1.99934817
Arroz_entrenamiento [Cyan1] 9525 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99939275
Arroz_entrenamiento [Cyan1] 9525 points and Pastizales_validación [Red2] 1150 points - 1.99940158
OtrasCoberturas_entrenamiento [Blue1] 7637 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99980793
OtrasCoberturas_entrenamiento [Blue1] 7637 points and Pastizales_validación [Red2] 1150 points - 1.99989653
Arroz_validación [Cyan2] 3176 points and MonteNativo_validación [Magenta2] 642 points - 2.00000000
Arroz_entrenamiento [Cyan1] 9525 points and MonteNativo_validación [Magenta2] 642 points - 2.00000000
Arroz_validación [Cyan2] 3176 points and OtrasCoberturas_validación [Blue2] 3136 points - 2.00000000
Arroz_validación [Cyan2] 3176 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 2.00000000
Arroz_entrenamiento [Cyan1] 9525 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 2.00000000
Arroz_entrenamiento [Cyan1] 9525 points and OtrasCoberturas_validación [Blue2] 3136 points - 2.00000000
Arroz_validación [Cyan2] 3176 points and MonteNativo_entrenamiento [Magenta1] 2160 points - 2.00000000
Arroz_entrenamiento [Cyan1] 9525 points and MonteNativo_entrenamiento [Magenta1] 2160 points - 2.00000000
```

Figura 4.27: Resultado de la separabilidad espectral de las ROIs realizadas sobre el dataset de imágenes de NDVI (S-2) obtenidas a través de ENVI

Una vez definidas las ROIs, se procedió a realizar la clasificación del dataset de imágenes (apiladas), conservando el mismo sistema de georeferenciación en todas las imágenes (WGS-84).

Se comenzó con la ClaSup de Mahalanobis Distance seleccionando en el ENVI las siguientes pestañas (Classification → Supervised → Mahalanobis Distance → Select Classes from Regions), debiendo ingresar en la última pestaña las ROIs seleccionadas para entrenamiento y por último, antes de correr el modelo se incorporó la máscara de áreas indeseadas.

De igual manera, se procedió a realizar la ClaNoSup de K-Means seleccionando en el ENVI las siguientes pestañas (Classification → Unsupervised → K-Means), utilizando el mismo dataset de imágenes (S-2) seleccionadas previamente.

Replicando el procedimiento desarrollado para la ClaSup de Mahalanobis Distance, se incorporó en el clasificador de K-Means la misma máscara de áreas indeseadas. Finalmente, se ajustaron los parámetros del algoritmo, donde se obtuvieron los mejores resultados del clasificador seleccionando un número de clases de 5, un umbral de cambio 5% y un máximo de 100 iteraciones, como límite dentro del cual el modelo alcanza la convergencia.

Sobre los mapas resultantes se midieron las precisiones de los clasificadores mediante el

cómputo de la matriz de confusión, seleccionando en el ENVI las siguientes pestañas → Classification → Post Classification → Confusion Matrix → Using Ground Truth ROIs (en esta última pestaña se incorporaron las ROIs de validación). Dicha matriz de confusión permite analizar la precisión general del clasificador (indica lo bien que el mapa identifica todos los tipos de coberturas clasificados), como así también el índice Kappa. Este último, indica la proporción de exactitud del clasificador sin tener en cuenta los aciertos por azar. La matriz de confusión computa la 'exactitud del productor' el cual, se calcula como la razón entre el número de unidades muestreadas que fueron correctamente clasificadas (diagonal de la tabla) y el número de unidades que pertenecen a esa categoría (campo). Se utiliza para calcular los errores de omisión (los píxeles que pertenecen a cierta clase no aparecen en ella por estar erróneamente incluidos en otra). El otro indicador visible en la matriz es el que determina la 'exactitud del usuario', el mismo relaciona el número de unidades muestreadas que fueron correctamente clasificadas (diagonal de la tabla) y el número total de unidades que forman esa clase en el mapa. A partir del mismo se obtiene el error de comisión (píxeles asignados a una clase en el mapa pero que no pertenecen a ella).

Para una mejor interpretación visual de los mapas finales, se les aplicó a los mismos un filtro de mayoría (post-clasificación) seleccionando en el ENVI las siguientes pestañas → 'Majority/Minority Analysis' → 'Analysis Method' → 'Majority' (ventana de 9 x 9 píxeles). A través de este filtro, se logra corregir el efecto de 'sal y pimienta' que tiene la imagen de salida generando píxeles espurios (clasificados erróneamente) dentro de una clase única grande a esa clase.

Por último, se generaron los mapas de impresión a través del software QGIS, manteniendo la misma paleta de colores para la diferenciación y comparación entre las diferentes coberturas de la imagen resultante en cada clasificador.

4.8.2. Clasificación con imágenes de radar (S-1)

Se seleccionó un total de 8 imágenes de radar (S-1) en la polarización VH (ver listado en anexo K), considerando la mayor sensibilidad de la retrodispersión (VH) en relación a la vegetación en pie (permitiendo una mejor interpretación de la contribución de la vegetación con respecto al componente suelo) [34], [96]. El área de estudio seleccionada para el mapeo e identificación de pastizales con imágenes de radar, coincide con el área analizada a partir de las imágenes ópticas (región centro-norte de Entre Ríos).

El dataset de imágenes de (S-1) fue previamente calibrada radiométricamente y geométricamente por medio del software SNAP (desarrollado en la sección 4.4.2). Luego, a través del software ENVI se realizó el apilamiento de dichas imágenes manteniendo el mismo sistema de georeferenciación utilizado en la clasificación lograda a partir de los datos ópticos (WGS-84).

Seguidamente, se aplicó al conjunto de imágenes un 'filtro de Frost' (ventana de 6 x 6 píxeles), para suavizar el ruido sistemático (speckle) característico de las imágenes SAR. Este filtro a demostrado un mejor desempeño que otros filtros para reducir el ruido conservando los bordes y amortiguando los valores de los píxeles para la clasificación de diferentes coberturas [97].

Una vez reducido el ruido en las imágenes se procedió con la ejecución de los algoritmos. En este sentido, se seleccionaron los mismos clasificadores usados previamente en base a la información óptica. Para la ClaNoSup → K-Means y para la ClaSup → Mahalanobis Dis-

4.8 IDENTIFICACIÓN Y MAPEO DE ÁREAS CON PASTIZALES EN LA REGIÓN CENTRO-NORTE DE ENTRE RÍOS UTILIZANDO IMÁGENES ÓPTICAS Y DE RADAR

tance, empleando análogamente la máscara para no contemplar aquellas áreas indeseadas. Asimismo, se utilizaron las mismas ROIs de entrenamiento y validación generadas aleatoriamente en las zonas de interés ('Pastizales', 'Cultivo de arroz', 'Monte nativo' y 'Otras coberturas').

Al igual que en las imágenes ópticas se verificó si las ROIs de entrenamiento y validación son suficientemente iguales entre si para ROIs de la misma clase y lo suficientemente independientes y diferenciables entre si para ROIs de clases distintas. Para esto, como se mencionó anteriormente, se seleccionó en el ENVI la pestaña 'Compute ROI separability' generando un cuadro de diálogo que expone al final del informe, la capacidad de separación de pares de ROIs (distancia de Jeffries-Matusita).

Como se observa en la figura 4.28, en dicho cuadro de diálogo se enumeran desde las ROIs menos separables a las más separables. Los resultados indican elevada homogeneidad en las ROIs de entrenamiento y validación para la misma clase, siendo el valor para las clases de 'Otras Coberturas' (0.268), seguida por las clases de 'Monte Nativo' (0.292), 'Pastizales' (0.321) y 'Arroz' (0.535), demostrando homogeneidad entre las coberturas de la misma clase.

En cuanto al análisis de separabilidad espectral de las distintas clases, se obtuvieron desde valores aceptables (superiores de 1.7) a excelentes (2.0) [98].

```
Pair Separation (least to most);
OtrasCoberturas_entrenamiento [Blue1] 7637 points and OtrasCoberturas_validación [Blue2] 3136 points - 0.26844847
MonteNativo_entrenamiento [Magenta1] 2160 points and MonteNativo_validación [Magenta2] 642 points - 0.29236695
Pastizales_entrenamiento [Red1] 2667 points and Pastizales_validación [Red2] 1150 points - 0.32170464
Arroz_entrenamiento [Cyan1] 9525 points and Arroz_validación [Cyan2] 3176 points - 0.53510172
OtrasCoberturas_validación [Blue2] 3136 points and Pastizales_entrenamiento [Red1] 2667 points - 1.70296544
OtrasCoberturas_entrenamiento [Blue1] 7637 points and Pastizales_entrenamiento [Red1] 2667 points - 1.73626928
OtrasCoberturas_validación [Blue2] 3136 points and Pastizales_validación [Red2] 1150 points - 1.82740939
OtrasCoberturas_entrenamiento [Blue1] 7637 points and Pastizales_validación [Red2] 1150 points - 1.85438701
Arroz_entrenamiento [Cyan1] 9525 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.91374041
Arroz_entrenamiento [Cyan1] 9525 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.94898123
Arroz_validación [Cyan2] 3176 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.95588663
Arroz_validación [Cyan2] 3176 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.96911086
Arroz_entrenamiento [Cyan1] 9525 points and MonteNativo_entrenamiento [Magenta1] 2160 points - 1.99316454
Arroz_entrenamiento [Cyan1] 9525 points and MonteNativo_validación [Magenta2] 642 points - 1.99550664
MonteNativo_entrenamiento [Magenta1] 2160 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.99674987
MonteNativo_validación [Magenta2] 642 points and OtrasCoberturas_entrenamiento [Blue1] 7637 points - 1.99795467
MonteNativo_entrenamiento [Magenta1] 2160 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.99931029
Arroz_entrenamiento [Cyan1] 9525 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99958318
Arroz_validación [Cyan2] 3176 points and MonteNativo_entrenamiento [Magenta1] 2160 points - 1.99960975
Arroz_validación [Cyan2] 3176 points and MonteNativo_validación [Magenta2] 642 points - 1.99978045
MonteNativo_validación [Magenta2] 642 points and OtrasCoberturas_validación [Blue2] 3136 points - 1.99980729
Arroz_entrenamiento [Cyan1] 9525 points and Pastizales_validación [Red2] 1150 points - 1.99984199
Arroz_validación [Cyan2] 3176 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99997701
Arroz_validación [Cyan2] 3176 points and Pastizales_validación [Red2] 1150 points - 1.99998282
MonteNativo_entrenamiento [Magenta1] 2160 points and Pastizales_entrenamiento [Red1] 2667 points - 1.99999996
MonteNativo_validación [Magenta2] 642 points and Pastizales_entrenamiento [Red1] 2667 points - 2.00000000
MonteNativo_entrenamiento [Magenta1] 2160 points and Pastizales_validación [Red2] 1150 points - 2.00000000
MonteNativo_validación [Magenta2] 642 points and Pastizales_validación [Red2] 1150 points - 2.00000000
```

Figura 4.28: Resultado de la separabilidad espectral de las ROIs realizadas sobre el dataset de imágenes con polarización VH (S-1) obtenidas a partir de ENVI

Luego de analizar la separabilidad espectral de las ROIs obtenidas desde las imágenes de radar, análogamente a las clasificaciones ópticas se utilizó el mismo procedimiento tanto en ClaSup como en ClaNoSup y posteriormente se analizaron las métricas de evaluación a partir de la matriz de confusión y el índice Kappa.

Para una mejor interpretación visual de los mapas resultantes, se eliminó al igual que en las imágenes de S-2 (post-clasificación), el efecto de 'sal y pimienta' (en ambos clasificadores) con el filtro 'Majority/Minority Analysis' (ventana de 9 x 9 píxeles) seleccionando el análisis

de mayoría para cambiar píxeles espurios dentro de una clase única grande a esa clase.

Por medio del software QGIS, se generaron los mapas de impresión manteniendo la misma paleta de colores para la diferenciación y comparación entre las diferentes coberturas de la imagen resultante en cada clasificador.

4.8.3. Desempeño de los algoritmos de clasificación

Primeramente, se evaluó post-clasificación el rendimiento de los modelos obtenidos a partir del test con el 30 % de áreas de validación analizando la precisión global y el índice Kappa de cada clasificador.

Seguidamente, se llevo a cabo (también en post-clasificación) una confrontación 'punto a punto' entre la verdad a campo, cuyas muestras con pastizales fueron obtenidas en 13 sitios distribuidos alrededor de la zona de estudio (se identifican en los mapas con puntos rojos georeferenciados) y la cobertura computada como 'Pastizales' del mapa final determinada por cada clasificador. El objetivo fue efectuar un análisis puntual de la proporción de aciertos por parte de los clasificadores seleccionados (Mahalanobis Distance y K-Means) en las áreas con presencia de pastizales.

También, se computó a partir de la superficie total (1517 Km²) de la zona de interés (departamento Feliciano), que porcentajes de superficie ocupan cada una de las coberturas obtenidas en los mapas finales. El cálculo se realizó teniendo en cuenta la cantidad de píxeles clasificados por el tamaño de cada píxel. El procedimiento se llevó a cabo sobre el conjunto seleccionado de imágenes ópticas y SAR a través de los algoritmos Mahalanobis Distance y K-Means.

Finalmente, se procedió a comparar la precisión general y la precisión de la cobertura de 'Pastizales' entre las diferentes clasificaciones logradas con un producto global validado, denominado 'Land Cover Classification' (precisión de mapeo general de poco más del 80 %) de Copernicus Global Land Service, el cual efectúa clasificaciones supervisadas con imágenes ópticas de Sentinel-2. Para confrontar los mapas clasificados, se descargó desde la plataforma Land Cover el mapa clasificado (en formato tiff) donde se recortó la misma zona de estudio dentro del departamento Feliciano (Entre Ríos) y se filtró la misma fecha del mapa de clasificación (ventana temporal del análisis, año 2017). A través del software QGIS se procedió a extraer un total de 250 puntos distribuidos aleatoriamente que caigan dentro de la extensión del área de interés, seleccionando las siguientes pestañas: Vectorial → Herramientas de investigación → Puntos aleatorios en la extensión. Teniendo en cuenta que, en la capa generada algunos puntos aleatorios se ubicaban dentro de la máscara de áreas indeseadas (cuerpos de agua, vías de escurrimiento y la ciudad de San José de Feliciano) fueron depurados resultando finalmente un total de 190 puntos (ver anexo L), que fueron analizados en una Matriz de Confusión observando en la misma el comportamiento de la Precisión del Productor y del Usuario.

Capítulo 5

Resultados y discusión

5.1. Resultados obtenidos en el proceso estimativo de biomasa de los pastizales mediante información satelital

5.1.1. Análisis de la regresión entre la materia seca de los pastizales y los datos ópticos (índice NDVI)

Región de Entre Ríos, Argentina

En la siguiente figura 5.1 se plasma la relación entre las muestras MIBIOP y los valores de NDVI resultantes del análisis de regresión lineal realizado en ambos sitios de estudio. Correspondiendo al 'sitio 1' la figura (a) donde se detallan los valores de NDVI extraídos a partir de la sinergia entre las imágenes S-2 y L-8. En la figura (b) se detalla la correlación entre las variables para el 'sitio 2'.

Cabe aclarar que para realizar dicho análisis de correlación, sólo se tuvieron en cuenta las fechas de adquisición de las imágenes ópticas en coincidencia con las fechas de medición de las MIBIOP que abarquen la etapa de crecimiento de los pastizales (desde septiembre-octubre hasta marzo-abril) para la ventana temporal considerada. En líneas generales, el índice de NDVI expone una alta sensibilidad con respecto a la biomasa de los pastizales de baja cobertura, el cuál aumenta rápidamente en etapas tempranas de crecimiento de la vegetación (etapa de rebrote), evolucionando hasta alcanzar el estado de saturación del índice (etapa con elevada producción de materia verde de los pastizales-máximo IAF) y luego descende en etapas avanzadas de crecimiento de los pastizales cuando la actividad fotosintética disminuye (comienza la senescencia de la vegetación-etapa reproductiva), aunque no necesariamente disminuya la producción de biomasa total. El retraso entre lo observado y lo medido, como se plasmó en los gráficos expuestos previamente (figura 4.15), dificulta el análisis de correlación existente entre dichas variables en ésta última etapa, produciendo un desequilibrio del índice generado por una ligera disminución en la reflexión de la banda roja debido a la saturación del área foliar y un aumento en la banda NIR debido al efecto de dispersión múltiple de la vegetación [99], [100].

Se observó, en muchos casos la tendencia del NDVI en áreas con pastizales es aproximadamente lineal hasta los 1000-1200 kgMS/ha y por encima de éstos valores comienza a saturarse [101], [102].

Analizando los gráficos obtenidos por medio del lenguaje de programación R (en ambos sitios de estudio), se observa una correlación positiva moderada [103] entre las muestras MIBIOP y los valores de NDVI en el 'sitio 1' obteniendo un $R^2=0.664$. En cuanto al resultado

5.1 RESULTADOS OBTENIDOS EN EL PROCESO ESTIMATIVO DE BIOMASA DE LOS PASTIZALES MEDIANTE INFORMACIÓN SATELITAL

de la correlación en el 'sitio 2', ésta fue débil, dónde el modelo de regresión sólo explica un 35 % de la variabilidad total de las observaciones.




Figura 5.1: Relación entre la biomasa de los pastizales y los valores de NDVI obtenidos a partir de la sinergia entre las imágenes S-2 y L-8 para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

El comportamiento general observado entre las variables MIBIOP y el índice NDVI, es similar para ambas áreas analizadas en las fechas correlacionadas dentro de la ventana temporal considerada (desde enero del 2016 a diciembre del 2018). Pero, evidencian diferentes ajustes de precisión de los modelos. Por lo cual, contemplando que ambos sitios están influenciados por las mismas condiciones climáticas, el factor suelo podría considerarse como la variable que explica dicha variación generada entre ambos sitios de estudio. Teniendo en cuenta las diferencias en profundidad y tipo de suelo sobre el que se desarrollan los pastizales analizados, siendo suelos mas productivos los del 'sitio 1' en relación al suelo arenoso somero del 'sitio 2' con zonas inundables y con menor cobertura vegetal dando lugar a una composición florística de especies mas pobre. Cabe señalar, que se utilizó el mismo método de muestreo de biomasa de los pastizales en ambos sitios y además, no se descarta la perturbación de la vegetación causada por el pastoreo vacuno (defoliación, tránsito y pisoteo de la vegetación, retorno por excretas) presente en la zona analizada.

Por lo tanto, las diferentes condiciones del suelo y los tipos de suelo, como el estado fenológico y la condición de la vegetación, pueden hacer que la biomasa sea más difícil de calcular a partir del NDVI [104].

Región de Val Mazia, Italia

Se observa en la siguiente figura 5.2 los resultados obtenidos del análisis de regresión lineal entre las variables MIBIOP y el índice NDVI correspondientes al área de estudio de la región de Val Mazia (Italia). Tener en cuenta que, en dicha región latitudinal en la ventana temporal analizada durante el año 2017, coincide con la etapa de crecimiento de la vegetación (desde mayo a octubre).




Figura 5.2: Relación entre la biomasa de los pastizales y los valores de NDVI extraídos desde los sensores S-2 y L-8 (región Val Mazia)

En el gráfico de correlación resultante se visualiza un coeficiente de determinación positivo débil ($R^2=0.533$), considerando que, al igual que en los sitios analizados en Argentina, la variación de productividad de los pastizales para ésta área de estudio, puede estar mas influenciada por el factor suelo, siendo poco profundo y expuesto a la erosión para esta zona de estudio de montaña, resultado generalmente menos fértiles y con una composición vegetal mas pobre. Cabe mencionar, que al igual que en Argentina esta zona de estudio también se encuentra pastoreada por animales, por lo cual existe la perturbación de la vegetación causada por la defoliación, tránsito, pisoteo de la vegetación y retorno por excretas.

5.1.2. Resultados estimativos de biomasa de los pastizales a partir de datos SAR

Región de Entre Ríos, Argentina

La siguiente figura 5.3 plasma los resultados obtenidos de las mejores correlaciones computadas (software R) entre MIBIOP y los valores de retrodispersión (polarización VH) por medio del análisis del modelo de SLR obtenido en ambos sitios de estudio.

Se destaca la mejor correlación en el 'sitio 1' en la polarización VH obteniendo un $R^2= 0.70$ (figura 'a'). En cuanto al 'sitio 2', el modelo de regresión sólo explica un 39% la variabilidad total de las observaciones en la polarización VH (figura 'b'), sin encontrar relación alguna entre las variables en la polarización VV en ambos sitios de estudio.

5.1 RESULTADOS OBTENIDOS EN EL PROCESO ESTIMATIVO DE BIOMASA DE LOS PASTIZALES MEDIANTE INFORMACIÓN SATELITAL

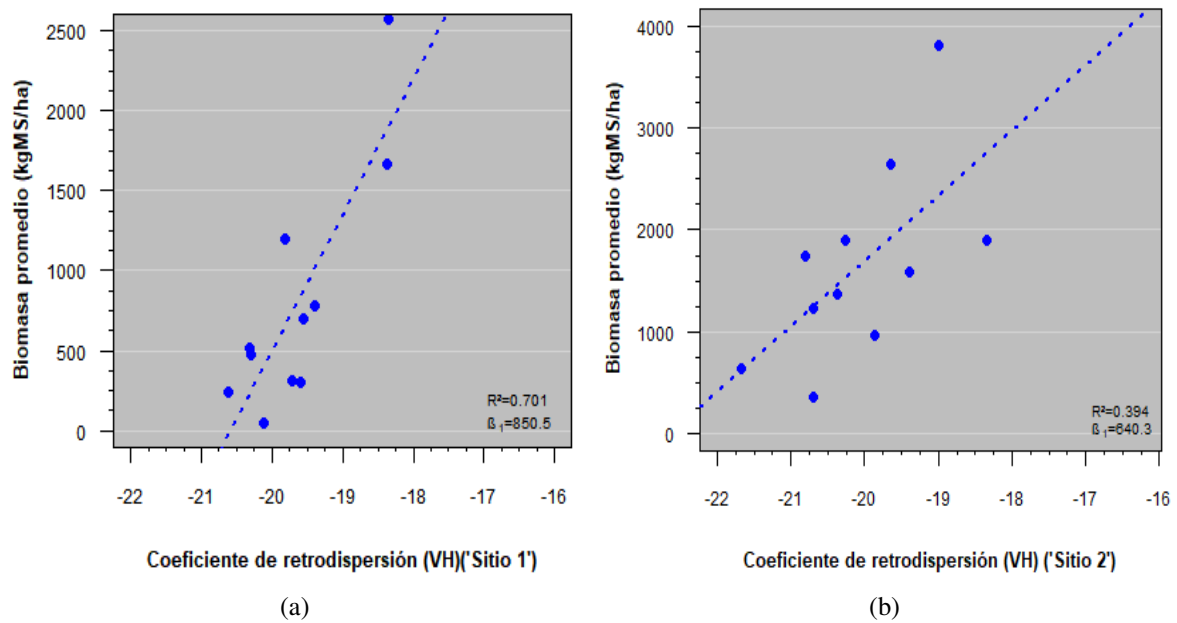


Figura 5.3: Relación entre la biomasa de los pastizales y los valores de retrodispersión en la polarización VH extraídos desde el sensor S-1 para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

Tal como lo demuestran los gráficos de dispersión, la variable explicativa que mejor repuesta obtuvo en relación a la evolución de biomasa de los pastizales fue el σ^0 en la polarización VH para el 'sitio 1'. Dichos valores de retrodispersión captados por el sensor S-1 que opera en la banda C, se componen de la retrodispersión generada entre la superficie vegetal y la subyacente (atenuada por dicha vegetación), e influenciada por mecanismos de dispersión entre el suelo y la vegetación propia. Por lo cuál, para esta situación la retrodispersión de la banda VH, aumenta más fuertemente con la dispersión por volumen que la retrodispersión de la banda VV (mayor sensibilidad a la dispersión por superficie), logrando una mejor correlación en relación al indicador de biomasa de los pastizales en este sitio de estudio [83].

En cuanto al comportamiento manifestado a partir de la variable Ratio VH/VV para la estimación de biomasa de los pastizales, los resultados de la correlación denotan que el modelo explica un 50 % la variabilidad total de las observaciones en el 'sitio 1' (figura 5.4 'a') y solo un 26 % en el 'sitio 2' (figura 5.4 'b'), siendo éstos valores intermedios entre los obtenidos a partir de la polarización VH y VV.

5.1 RESULTADOS OBTENIDOS EN EL PROCESO ESTIMATIVO DE BIOMASA DE LOS PASTIZALES MEDIANTE INFORMACIÓN SATELITAL




Figura 5.4: Relación entre biomasa de los pastizales y los valores de ratio VH/VV para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

Región de Val Mazia, Italia

Los resultados obtenidos a partir del modelo de SLR generado entre la variable del σ^0 (polarización VH y VV) en correspondencia con los valores de MIBIOP para la región de Val Mazia, se plasman en la siguiente figura 5.5.




Figura 5.5: Relación entre la biomasa de los pastizales y los valores de retrodispersión en la polarización VH (a) y VV (b) (región de Val Mazia)

5.1 RESULTADOS OBTENIDOS EN EL PROCESO ESTIMATIVO DE BIOMASA DE LOS PASTIZALES MEDIANTE INFORMACIÓN SATELITAL

Se observa en este caso, una moderada correlación entre las variables analizadas en la polarización VH (figura 5.5 'a') dando como resultado un $R^2= 0.64$ y obteniendo en el análisis con la polarización VV una moderada-débil correlación cuyo $R^2= 0.51$ (figura 5.5 'b').

En coincidencia con los resultados obtenidos en Argentina el σ^0 en la banda VH fue la variable que mejor respuesta obtuvo para interpretar la biomasa de los pastizales en la región montañosa de Val Mazia. Asociándose los valores más altos de retrodispersión, con el período donde la biomasa de los pastizales generalmente alcanza el valor máximo de productividad (alrededor de 2000 kgMS/ha) [34].

A diferencia de los sitios analizados en Argentina, el σ^0 en la banda VV manifestó una respuesta estimativa de la biomasa de alrededor del 50% con respecto a la variabilidad total de las observaciones, y la variable Ratio VH/VV, no obtuvo correlación alguna con respecto a la variable MIBIOP.

Teniendo en cuenta la baja productividad de los pastizales presentes a elevadas altitudes como en la región analizada (suelos menos fértiles, composición vegetal mas pobre), la retrodispersión en el canal VV podría estar mas influenciada por la contribución del suelo desnudo (elevada rugosidad de la superficie) en interacción con las estructuras de la vegetación característica con hojas y tallos delgados y estrechos [34].

5.2. Evaluación del comportamiento de las variables del modelo MLR para la estimación de biomasa de los pastizales

Región de Entre Ríos, Argentina

Hasta el momento se obtuvieron correlaciones de las variables seleccionadas por medio de un modelo de SLR. En esta sección, se evaluaron los resultados alcanzados involucrando más de una variable predictiva en el proceso de estimación de biomasa de los pastizales para ambos sitios de estudio en Argentina a través del modelo MLR.

Se visualiza a continuación los resultados estadísticos computados por medio del software R para la acción del modelo MLR (descrito en la sección 4.6) integrado por la selección de los valores del índice NDVI (sinergia entre los sensores S-2 y L-8), junto al σ^0 (VH) y Ratio VH/VV (extraídos desde el sensor SAR S-1) para el 'sitio 1'.

- Total de observaciones = 10 por variable.
- Coeficiente de determinación $R^2 = 0,844$.
- Error cuadrático medio RMSE = 268.5 (kgMS/ha)
- Coeficientes de la regresión =
 - $\beta_0 \rightarrow$ Intercepción: 17970,5.
 - $\beta_1 \rightarrow \sigma^0$ VH (S-1): 667,4.
 - $\beta_2 \rightarrow$ Ratio VH/VV (S-1): 651,7.
 - $\beta_3 \rightarrow$ NDVI (complemento de S-2 y L-8): -558,1.

Los datos utilizados como entrada al modelo MLR dentro del ejecutable R para el análisis en el 'sitio 2', se corresponden también con las variables de NDVI, sumado al σ^0 (VH) y ratio VH/VV en el proceso estimativo de biomasa de los pastizales. Los resultados que arrojó el modelo MLR se detallan a continuación:

- Total de observaciones = 10 por variable.
- Coeficiente de determinación $R^2 = 0,508$.
- Error cuadrático medio RMSE = 479.3 (kgMS/ha)
- Coeficientes de la regresión =
 - $\beta_0 \rightarrow$ Intercepción: 14802,1.
 - $\beta_1 \rightarrow \sigma^0$ VH (S-1): 572,4.
 - $\beta_2 \rightarrow$ Ratio VH/VV (S-1): 236,6.
 - $\beta_3 \rightarrow$ NDVI (complemento de S-2 y L-8): -624,1.

5.2 EVALUACIÓN DEL COMPORTAMIENTO DE LAS VARIABLES DEL MODELO MLR PARA LA ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

Como se expresan en los resultados para ambos sitios de estudio la integración de las variables a partir de la información óptica y SAR mejoró la precisión de estimación de biomasa [105], obteniendo un $R^2 = 0,844$ y $RMSE = 268.5$ para el 'sitio 1' y un $R^2 = 0,508$ y $RMSE = 479.3$ para el 'sitio 2', en comparación a los resultados logrados con dichas variables en el análisis del modelo de SLR.

En los siguientes gráficos se visualiza la relación entre los valores de biomasa de los pastizales medidos a campo (*in situ*) y los valores estimados a partir del del modelo MLR para el 'sitio 1' (figura 5.6 'a') y para el 'sitio 2' (figura 5.6 'b').




Figura 5.6: Relación entre la biomasa *in situ* de los pastizales y la biomasa estimada a través del modelo MLR para el 'sitio 1' (a) y el 'sitio 2' (b) (Entre Ríos)

Tal como se observa en los gráficos en el 'sitio 1' se obtuvo una regresión lineal sólida entre la biomasa medida *in situ* y la estimada por el modelo MLR, a diferencia del 'sitio 2' donde se presentó una sub-estimación de la biomasa de los pastizales. Esta baja correlación podría atribuirse al estado de saturación del índice NDVI en áreas con vegetación densa donde se pierde la sensibilidad ante valores mas altos de biomasa [100]. Dicho comportamiento se corresponde con el resultado logrado por C. Finnigan [106], donde se utilizó un modelo de regresión multilínea con imágenes ópticas (Landsat-5) y SAR (RADARSAT-2) para el monitoreo de biomasa de pastizales. Dicho modelo pudo explicar el 74% de la variación en la biomasa verde medida, aunque subestima la biomasa verde, en áreas de mayor densidad del dosel.

Región de Val Mazia, Italia

Para el sitio de estudio secundario ubicado en la región de Val Mazia (Italia) las variables seleccionadas como entrada al modelo MLR (NDVI, σ^0 en la polarización VH y VV) también, lograron mejorar la precisión estimativa de biomasa de los pastizales en comparación con el aporte individual alcanzado por cada variable según el modelo de SLR, obteniendo un $R^2 = 0,847$ y $RMSE = 173.9$.

A continuación se exponen los resultados estadísticos computados a través del software R

5.2 EVALUACIÓN DEL COMPORTAMIENTO DE LAS VARIABLES DEL MODELO MLR PARA LA ESTIMACIÓN DE BIOMASA DE LOS PASTIZALES

para el modelo MLR:

- Total de observaciones = 10 por variable.
- Coeficiente de determinación $R^2 = 0,847$.
- Error cuadrático medio RMSE = 173.9 (kgMS/ha)
- Coeficientes de la regresión =
 - $\beta_0 \rightarrow$ Intercepción: 6412.76.
 - $\beta_1 \rightarrow \sigma^0$ VH (S-1): 294.33.
 - $\beta_2 \rightarrow \sigma^0$ VV (S-1): 104.96.
 - $\beta_3 \rightarrow$ NDVI (complemento de S-2 y L-8): 1414.80.

Finalmente, el siguiente gráfico 5.7 expresa la relación entre los valores de biomasa de los pastizales medidos a campo y los valores estimados mediante el modelo MLR para el área de estudio de Val Mazia.

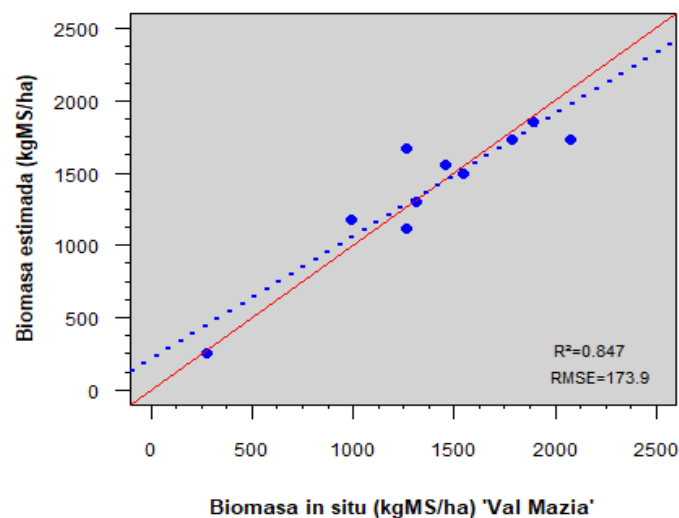


Figura 5.7: Relación entre la biomasa *in situ* de los pastizales y la biomasa estimada a través del modelo MLR (región de Val Mazia)

5.3. Mapa estimativo de biomasa de los pastizales

En la siguiente figura 5.8 se visualiza el mapa final estimado de biomasa de los pastizales para la fecha 15/12/2017, obtenido a partir del modelo MLR por medio de la integración de datos ópticos y SAR para un área específica que abarca el 'sitio 1' de estudio y su entorno (región sur-este de Entre Ríos). Para la generación de dicho mapa se utilizaron los coeficientes de regresión de las variables seleccionadas para la ejecución del modelo MLR en el 'sitio 1' (desarrollado en la sección 5.2).

Mapa de biomasa estimada de los pastizales a partir del modelo MLR (15/12/2017)




Figura 5.8: Mapa estimativo de biomasa de los pastizales a través del modelo MLR (sur-este de Entre Ríos)

Cabe aclarar que las pruebas realizadas poseen un enfoque de sitio específico. Dada la variabilidad productiva intra e interanual que presentan los pastizales, asociada principalmente a las características estructurales de la vegetación, como así también ambientales (topográficas y edáficas) e influenciadas por las condiciones climáticas, dificulta la determinación de la carga animal en diferentes establecimientos dentro del ejido de Entre Ríos. Esta alta variabilidad puede provocar muchas veces una sub-utilización del forraje, o también la sobre-explotación con el consecuente deterioro de los recursos forrajeros y edáficos [107].

5.4. Mapas resultantes según algoritmos de clasificación seleccionados

5.4.1. Mapas obtenidos mediante imágenes ópticas

Clasificación supervisada de Mahalanobis Distance

A partir de la clasificación supervisada de Mahalanobis Distance realizada sobre el dataset de imágenes ópticas (S-2), se obtuvo un mapa final cuya matriz de confusión resultante (ver anexo J) arroja una precisión general de 89.2% y un índice Kappa de 0.85 (considerado como valor 'excelente' según [108]). El mismo se observa en la siguiente figura 5.9 donde se pueden diferenciar las coberturas clasificadas a partir del conjunto de imágenes (S-2), identificando con color verde claro las zonas con pastizales, en marrón se distinguen las áreas destinadas a la producción de arroz, el color verde oscuro señala sectores con monte nativo. Finalmente, se indican las zonas de 'Otras coberturas' en color mostaza y la máscara aplicada a la clasificación se observa en negro.

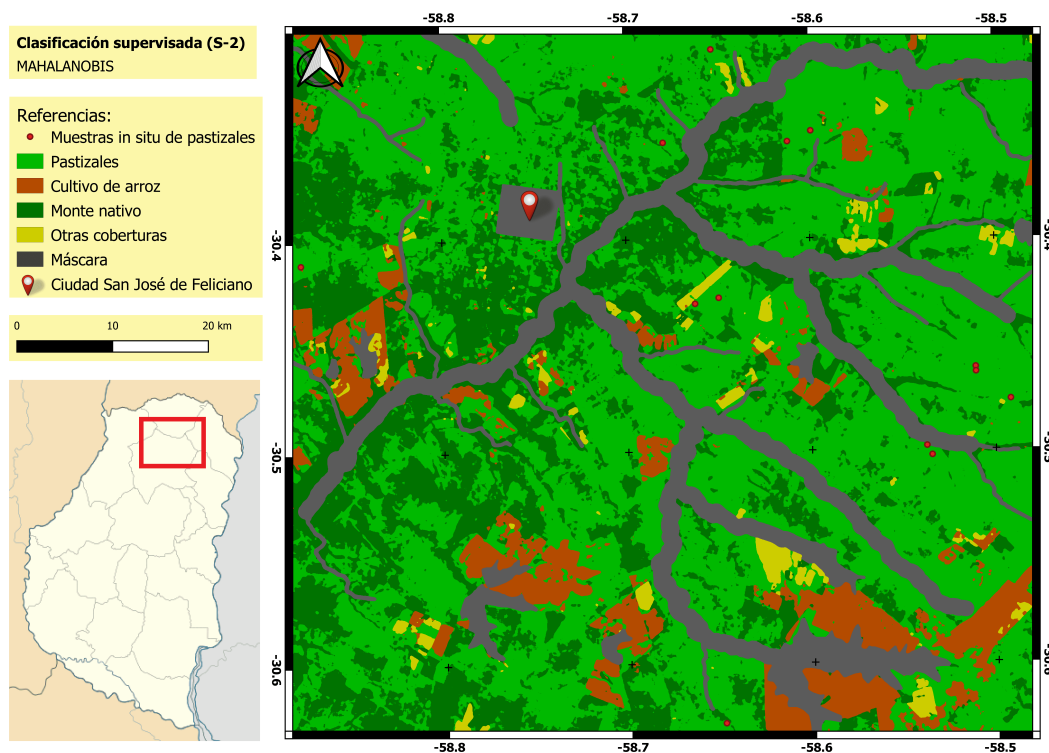


Figura 5.9: Clasificación supervisada Mahalanobis Distance (S-2), en la región centro-norte de Entre Ríos

Clasificación no supervisada K-Means

Como se observa en la figura 5.10, el mapa resultante de la clasificación no supervisada utilizando el algoritmo K-Means sobre el dataset de imágenes ópticas seleccionadas, obtuvo una precisión general de 93.91% y un índice Kappa de 0.91 (considerado como valor 'excelente' según [108]) (ver resultados de la matriz de confusión en el anexo I).

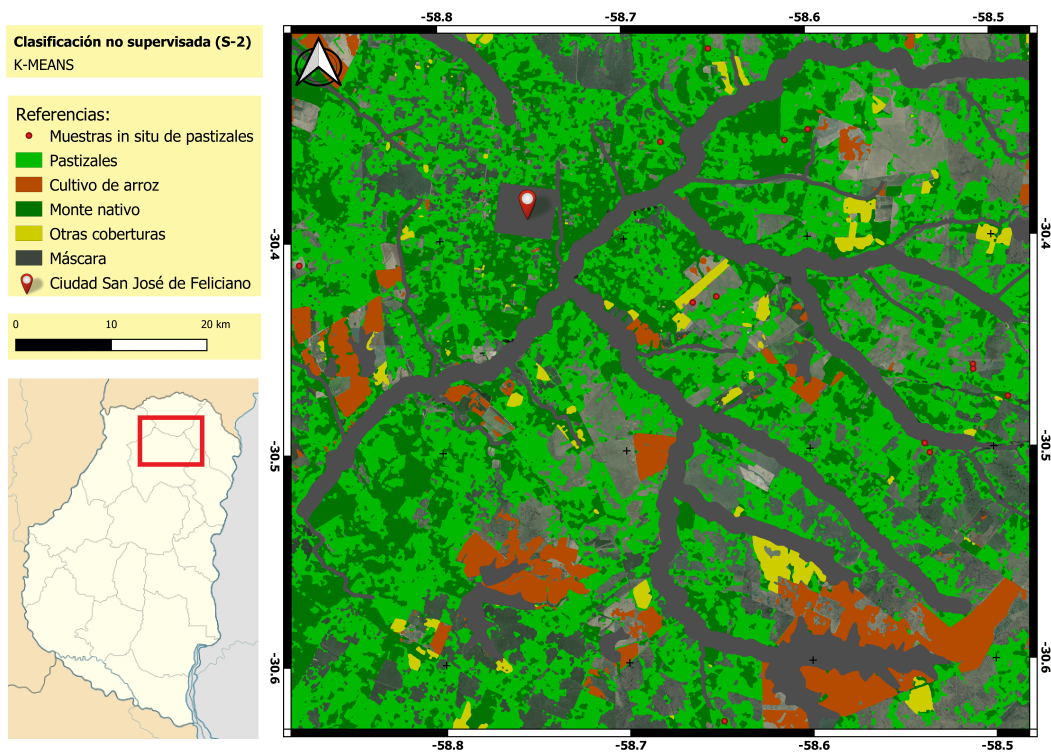


Figura 5.10: Clasificación no supervisada K-Means (S-2), en la región centro-norte de Entre Ríos

5.4.2. Mapas obtenidos mediante imágenes SAR

Clasificación supervisada de Mahalanobis Distance

La mapa resultante de la clasificación con Mahalanobis Distance obtenido a partir del dataset de imágenes radar (S-1), se visualiza a continuación (ver figura 5.11). Con el fin de determinar la precisión de dicho mapa, se procedió al cómputo de la matriz de confusión (ver anexo I) cuya precisión general fue de 92.7% y el índice Kappa de 0.89 (considerado como valor 'excelente' según [108]).

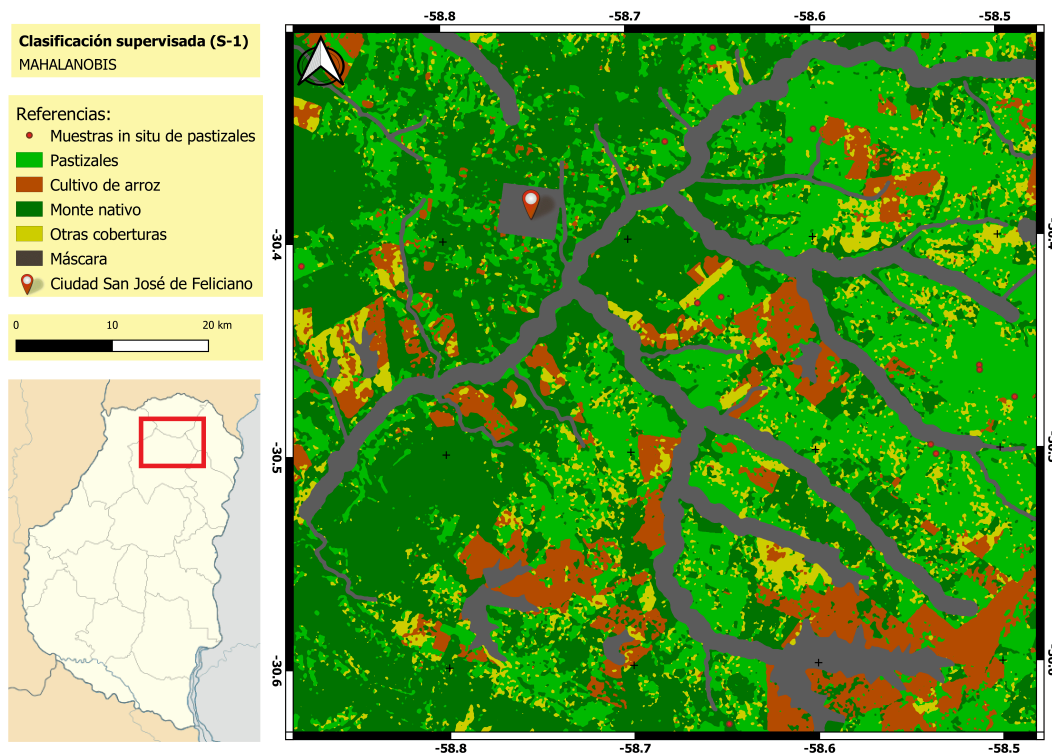


Figura 5.11: Clasificación supervisada Mahalanobis Distance (S-1), en la región centro-norte de Entre Ríos

Clasificación no supervisada K-Means

La clasificación no supervisada K-Means realizada sobre el conjunto de imágenes radar (S-1) obtuvo como resultado el siguiente mapa final (ver figura 5.12). Los resultados de los estadísticos de la matriz de confusión (ver anexo I) alcanzaron una precisión general de 85 % y un índice Kappa de 0.79 (considerado como valor 'muy bueno' según [108]).

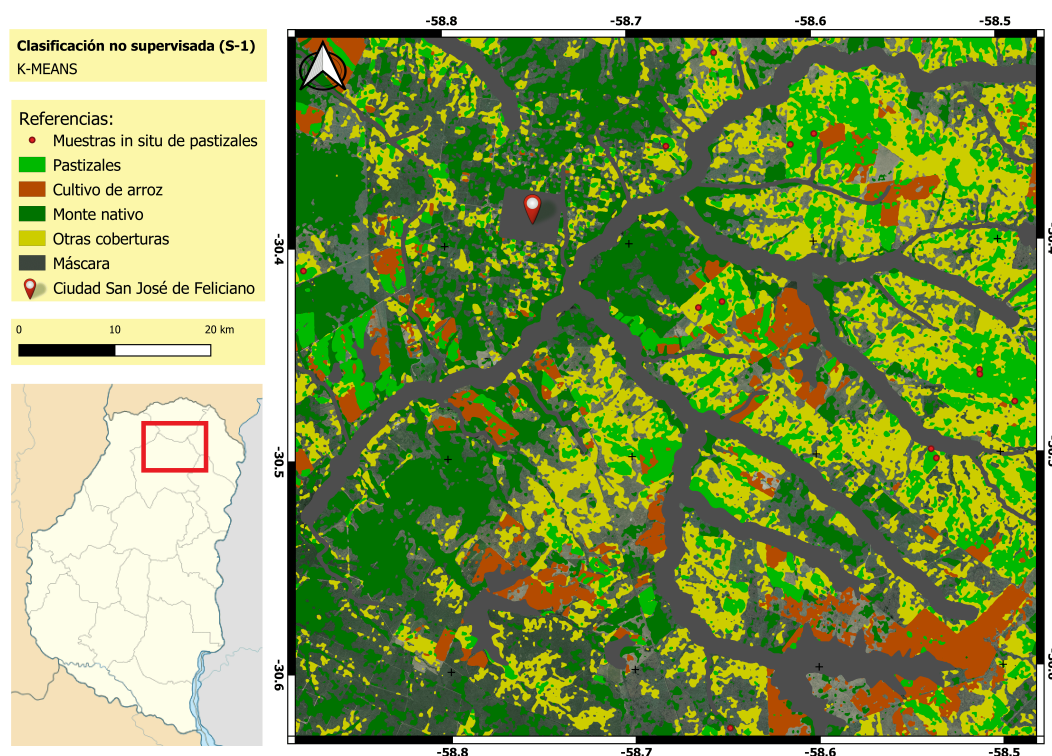


Figura 5.12: Clasificación no supervisada K-Means (S-1), en la región centro-norte de Entre Ríos

5.4.3. Análisis del desempeño de los algoritmos de clasificación

Los resultados obtenidos a partir de los clasificadores seleccionados, muestran que la serie de tiempo analizada por ambos sensores puede lograr una precisión de clasificación muy buena con más del 85 % de precisión global y un índice Kappa superior a 0.79 (ver figura 5.13). Teniendo en cuenta que para lograr optimizar dicho nivel de precisión en el período de adquisición de datos considerado, se precisó como mínimo un conjunto de 5 imágenes ópticas libres de nubes y un total de 8 imágenes SAR como lo recomienda [18].

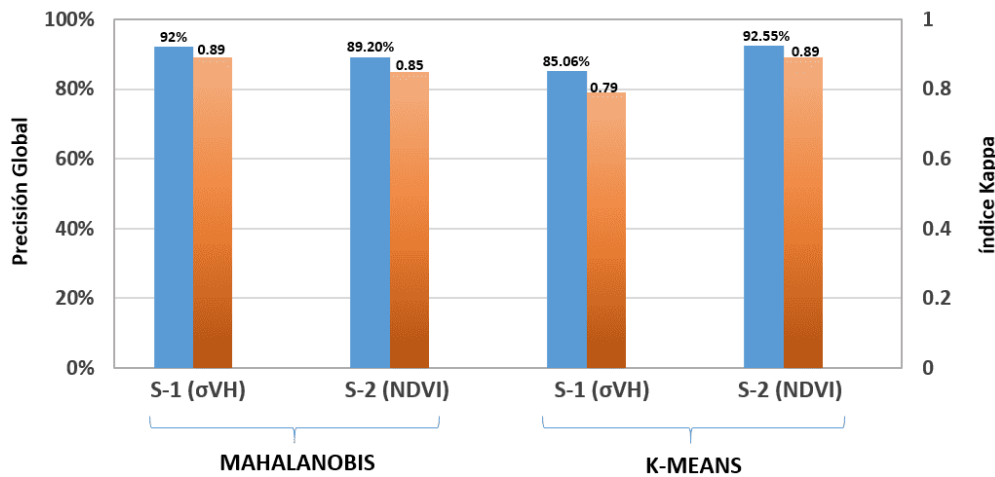


Figura 5.13: Precisión global e índice Kappa obtenidos en los clasificadores evaluados en la región centro-norte de Entre Ríos

Además del análisis de la performance de los modelos se evaluó a continuación a modo puntual (ver figura 5.14) la proporción de aciertos a partir de la clase computada como 'Pastizales' del mapa resultante para cada clasificador, contrastada con la información de campo o verdad de terreno para una validación puntual de resultados (identificación de 13 puntos georeferenciados ubicados en sitios relevados con pastizales, distribuidos en la zona de interés).

Tener en cuenta que, para llevar a cabo dicha la validación se comparó 'punto a punto' las áreas clasificadas como pastizales en relación a los datos derivados del relevamiento a campo, obteniendo un elevado porcentaje de aciertos a partir del mapa resultante del algoritmo Mahalanobis ejecutado sobre las imágenes de radar y ópticas (100 % y 92.3 % respectivamente). El algoritmo de K-Means logró un 84.6 % de aciertos a partir de los datos radar y una moderada a baja precisión con respecto al mapa final obtenido a partir de los datos ópticos (53.8 %).

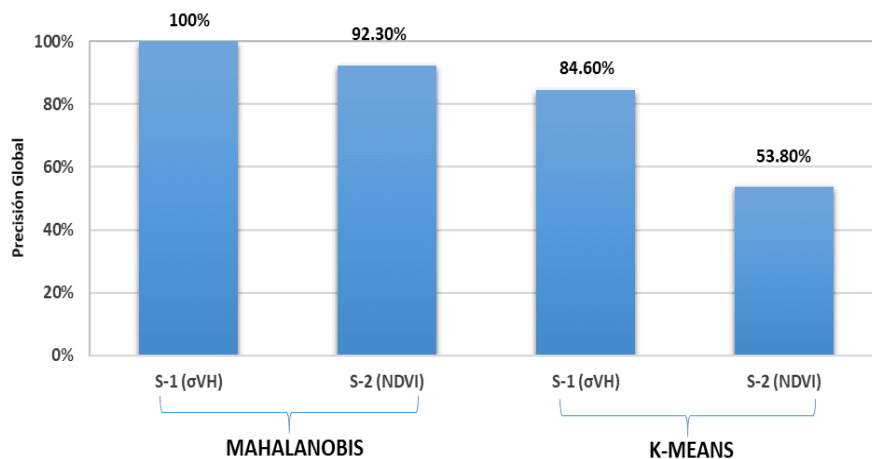


Figura 5.14: Validación entre las áreas clasificadas como pastizales y la verdad de campo en la región centro-norte de Entre Ríos

También, se cuantificaron los porcentajes de superficie que ocupan las diferentes coberturas obtenidas de los mapas finales por medio de los clasificadores de Mahalanobis Distance y K-Means. Los resultados se plasman en la siguiente tabla comparativa 5.1.

Tabla 5.1: Distribución de las coberturas (en porcentaje) para cada clasificador analizado en la región centro-norte de Entre Ríos

	Clasificación con MAHALANOBIS		Clasificación con K-MEANS	
	S-1 (σ^0 VH)	S-2 (NDVI)	S-1 (σ^0 VH)	S-2 (NDVI)
Pastizales	34.1 %	44.6 %	14.4 %	38 %
Monte Nativo	34.5 %	29.9 %	18.6 %	16.3 %
Otras Coberturas	8.2 %	3.7 %	21 %	2.8 %
Cultivo de Arroz	9.5 %	8.1 %	6.5 %	6.2 %
Máscara	13.7 %	13.7 %	13.7 %	13.7 %
Clase no asignada	0 %	0 %	25.8 %	23 %


Como se observa en la tabla, se presenta un elevado porcentaje de cobertura de 'Pastizales' obtenido a partir de la ClaSup de Mahalanobis Distance realizado sobre el conjunto de imágenes ópticas y SAR (44.6 % y 34.1 % respectivamente), como así también, el resultado alcanzado por la ClaNoSup del algoritmo K-Means a partir de los datos ópticos (38 % de cobertura), pero a partir de los datos SAR solo clasificó un 14.4 % de esta cubierta vegetal. Pudiendo ser atribuido dicho valor cuantificado por K-Means de la clase 'Pastizales', a que hubo un 25.8 % de áreas no asignadas a una clase y posiblemente se constituyan las mismas de un elevado porcentaje de píxeles que podrían pertenecer a dicha clase con pastizales, o el clasificador K-Means computó que ciertos píxeles pertenecían a la clase 'Otras coberturas' cuando en realidad corresponden a la clase 'Pastizales' (porcentaje de ocupación elevado de 21 % en comparación al área estimada para dicha clase identificada en el resto de los mapas generados).

Las características fisiográficas y distribución espacial de la vegetación en la zona de estudio constituyen fases intermedias entre una cobertura de pastizal puro y un matorral o monte


(en la cual las estructuras son mayores y más densas) en las que el clasificador las considera como una clase intermedia (ver en la figura 5.15 los diferentes estratos de vegetación estudiados). Dichas coberturas vegetales poseen similares respuestas en los valores de retrodispersión que llegan al sensor de radar, en consecuencia, se produce una confusión por parte del algoritmo de clasificación (no supervisado) para la correcta selección de los píxeles que conforman cada clase, teniendo en cuenta además de la elevada sensibilidad de la señal SAR con respecto a la dinámica de la estructura del dosel, como su constante dieléctrica y la interacción entre la vegetación y el suelo [83].

La señal de radar de banda C en la polarización VH, al interactuar con las coberturas de renovales se produce una atenuación de la retrodispersión en relación a las coberturas de monte, debido a la menor presencia de componentes estructurales de la vegetación (dominio de los mecanismos de dispersión por superficie sobre aquellos de dispersión por volumen) [109]. El mecanismo de dispersión dominante sobre los pastizales en la banda C es la dispersión por volumen donde la retrodispersión posee mayor sensibilidad a los elementos de dispersión más pequeños y las capas herbáceas bajas [110].

Pastizales con árboles y arbustos aislados



Monte nativo con arbustal denso



Renoval




Figura 5.15: Visualización de diferentes estratos de vegetación considerados en la clasificación [111]

Finalmente, se llevo a cabo una comparación entre las diferentes clasificaciones con un producto global validado, denominado 'Land Cover Classification' de Copernicus Global Land Service. El mapa obtenido desde dicha plataforma se visualiza en el anexo M, en el mismo se distinguen las diferentes coberturas clasificadas donde se le agregó también los puntos muestreados *in situ* con pastizales para la ubicación visual de los mismos en el mapa (puntos rojos georeferenciados).

Los resultados obtenidos entre los mapas clasificados confrontados con el producto validado mediante el análisis de la matriz de confusión a partir de los puntos aleatorios obtenidos dentro de la extensión del área de estudio (ver obtención de puntos en la sección 4.8.3) demuestran que, alcanzaron una muy buena precisión general del 85 % a partir del algoritmo Mahalanobis Distance sobre el conjunto de imágenes S-1 y S-2. Por su parte el algoritmo K-Means obtuvo una precisión general del 81 % realizado sobre el conjunto de imágenes de S-2 y una moderada a baja precisión de sólo el 60 % sobre el dataset de imágenes radar (S-1).

Seguidamente se analizaron los estadísticos Precisión del Productor (PP) y Precisión del Usuario (PU) tal como se observa en la tabla 5.2 para estudiar el grado de aciertos o errores presentes sólo en la clase 'Pastizales'.

Tabla 5.2: Porcentajes de precisión del usuario y productor en la clase 'Pastizales'

Clasificación con MAHALANOBIS				Clasificación con K-MEANS			
S-1 (σ^0 VH)		S-2 (NDVI)		S-1 (σ^0 VH)		S-2 (NDVI)	
PP	PU	PP	PU	PP	PU	PP	PU
98 %	78 %	87 %	89 %	83 %	41 %	85 %	83 %

Al mirar la tabla, la PP nos indica que los píxeles que fueron referenciados como 'Pastizales' (extraídos del muestreo de puntos aleatorios en los mapas), han sido clasificados con una exactitud superior al 83 % usando el algoritmo K-Means y superior al 87 % para Mahalanobis. Al observar los valores de PU se obtuvo una exactitud superior al 78 % usando el algoritmo Mahalanobis y con K-Means la PU obtenida a partir del dataset óptico fue 83 %, pero cabe resaltar una menor precisión lograda con el dataset SAR del 41 %, indicando que algunos píxeles del mapa clasificado pertenecientes a la clase 'Pastizales' aparecen en otras clases (en su mayoría en la clase 'Otras Coberturas').

La imagen clasificada por K-Means identifica un píxel como 'Otras Coberturas', pero la referencia lo identifica como 'Pastizales'. La clase 'Otras Coberturas' tiene píxeles extras que no debería tener según los datos de referencia.

Debido a la gran variabilidad florística y estructural de las coberturas vegetales analizadas sumado al ruido speckle 'efecto sal y pimienta' presente en las imágenes SAR, se genera una confusión al clasificador K-Means para el correcto agrupamiento de píxeles que conforman cada clase.

Capítulo 6

Conclusiones

Teniendo en cuenta la primera parte de este trabajo de investigación en el modelado de la producción de biomasa de los pastizales, los resultados logrados aplicando un modelo de SLR demuestran que los valores de retrodispersión en la polarización VH manifestaron la mejor respuesta estimativa de biomasa en relación a las MIBIOP para las series temporales analizadas, tanto en los sitios de estudio en Entre Ríos (Argentina) como en área analizada en la región de Val Mazia (Italia). Por lo tanto, se concluye que la polarización VH (en la banda C) es la más adecuada para describir las características de la vegetación (mecanismos de dispersión de volumen dominante) [34], [47], [83], [109].

La información derivada de datos complementarios entre los sensores ópticos de S-2 y L-8, obtuvieron una menor precisión del modelo de SLR (en relación a la variable de radar VH) tanto en los sitios analizados en Entre Ríos como en Val Mazia. Entre las causas, se encuentra la cobertura nubosa que limita la disponibilidad de imágenes ópticas en fechas deseadas, teniendo en cuenta que la zona de estudio de Entre Ríos presenta elevadas precipitaciones en la estación estival de crecimiento de los pastizales y en el caso de estudio de Val Mazia se trata de una región de montaña donde son concurrentes los días nublados. Sumado a la saturación temprana de los valores del índice NDVI que tiende a ser un indicador deficiente para la estimación de la biomasa en cubiertas vegetales densas, siendo útil para una cubierta vegetal escasa a moderada [101].

El modelo MLR que integró información proveniente de la sinergia entre los sensores ópticos (valores de S-2 y L-8) junto con los datos de radar (valores de σ_0 en la polarización VH y ratio VH/VV), mejoró la precisión de estimación de biomasa de los pastizales en ambos sitios de estudio en Entre Ríos, con un $R^2=0.844$ y RMSE=268.5 para el 'sitio 1' y un $R^2=0.508$ y RMSE=479.3 para el 'sitio 2'. Replicando la mejora en la precisión del modelo MLR para el área de estudio secundaria de Val Mazia obteniendo un $R^2=0.847$ y RMSE=173.9. Se deduce que la integración conjunta de datos ópticos y de radar logró un mejor ajuste del modelo de predicción MLR que el modelo SLR. De esta manera combinando imágenes de múltiples fuentes de datos, podría mejorar el proceso de extracción de diferentes variables biofísicas de las cubiertas vegetales, generando información complementaria para la descripción de la biomasa [34], [105].

Cabe señalar que, mediante éstos modelos predictivos no se logró representar a la serie temporal completa de datos disponibles en los sitios de estudio de Entre Ríos (desde diciembre del 2015 a noviembre del 2018), debido a la falta de consistencia espacio-temporal entre las MIBIOP y la información proveniente de las imágenes satelitales, limitando el análisis multitemporal realizado para estimar la biomasa de los pastizales ya que se redujo el número de datos posibles para lograr una correlación mas precisa entre las variables utilizadas [99].

La información generada por el mapa estimativo de biomasa de los pastizales, permitiría a usuarios / productores agropecuarios disponer de una herramienta de soporte extra en la toma de decisiones para el ajuste de variables productivas como la carga animal instantánea de la hacienda con la mayor eficiencia posible (número de animales por unidad de superficie de un potrero en un momento o instante dado) [88]. Tomar decisiones de manejo, regulando la disponibilidad de forraje / alimento por animal y por hectárea en su sistema de producción en función del cambio en las condiciones ambientales o del pastizal, y de la producción animal, como así también, tramitar la venta de terneros en un sistema de cría o la compra de terneros o novillitos en un sistema de invernada, entre otras decisiones de gestión en un sistema productivo ganadero.

Entre los múltiples factores que pueden haber afectado o alterado a los modelos estimativos de biomasa de los pastizales se detallan las condiciones atmosféricas, la saturación de los índices de vegetación, datos de MIBIOP insuficientes, variables biofísicas del suelo y la vegetación, influencia de factores climáticos, píxeles mixtos, los algoritmos seleccionados, como así también no menos importante la influencia del pastoreo vacuno al momento de recolección de datos a campo en los sitios de interés, lo cual pudo afectar la calidad de dichos datos [112].

Para poder determinar si existe una relación no lineal entre las variables provenientes de datos ópticos y de radar en el proceso estimativo de biomasa de los pastizales, se sugiere el uso de algún modelo de aprendizaje automático (redes neuronales) que utilice funciones no lineales en el análisis estadístico, incorporando parámetros polarimétricos (información SAR) que caractericen las múltiples fuentes de dispersión típicas de las cubiertas vegetales como es el caso de las imágenes de radar (full polarimétricas) provenientes de los satélites SAOCOM en banda L, en combinación con índices como el NDVI, GNDVI, SAVI, TSAVI, EVI, NBDI (obtenidos a partir de sensores ópticos) desarrollando de esta manera nuevas técnicas con fusión de datos que puedan estimar con mayor precisión la biomasa de los pastizales. Para ello, cabe aclarar que se precisa una considerable cantidad de datos de muestreo a campo utilizados como entrada del modelo estadístico, proporcionando la base necesaria para el entrenamiento de la red neuronal con el propósito de minimizar los errores de salida del modelo, lo que constituyó una clara limitante en este trabajo de investigación [113].

Se sugiere también, realizar nuevas pruebas de correlación utilizando otras variables obtenidas a partir de datos SAR como el índice RVI, mediante componentes de descomposición Cloude-Pottier (Entropía, Anisotropía y ángulo Alfa) o el uso de técnicas interferométricas, entre otras. Desarrollando de esta manera, modelos que pueden mejorar efectivamente la estabilidad de las estimaciones de biomasa de los pastizales.

Con respecto a experiencia de clasificación en áreas de interés con pastizales en la Región centro-norte de Entre Ríos (Argentina), hubo una respuesta positiva por parte de los algoritmos seleccionados, logrando una precisión de clasificación con más del 85 % de precisión global y un índice Kappa superior a 0,79. Destacando el mejor desempeño del algoritmo Mahalanobis Distance sobre el dataset de imágenes radar y ópticas seleccionadas, en relación al producto validado usado 'Land Cover Classification' para la diferenciación de coberturas vegetales, como así también, al comparar 'punto a punto' las áreas clasificadas como pastizales en relación a los datos de verdad a campo (13 puntos georeferenciados ubicados en sitios relevados con pastizales), obteniendo un total de aciertos del 100 % mediante la clasificación con datos SAR y 92 % en función de datos ópticos.

A partir de la evaluación y comparación de los métodos de clasificación aquí presentados se recomienda el uso del algoritmo de Mahalanobis Distance en función de datos SAR (S-1)

el cual logra muy buenos resultados en la discriminación de distintos tipos de coberturas vegetales.

La respuesta espectral de los pastizales es una integración compleja de diferentes especies con características espectrales distintas, generando cierto grado de incertidumbre en la diferenciación de este tipo de vegetación con respecto a otras especies arbóreas con las que conviven. A pesar de ello, se obtuvieron buenos resultados tanto en la clasificación supervisada como en la no supervisada a partir de datos ópticos con el índice NDVI (uno de los índices de vegetación más frecuentemente aplicados para el análisis de la cobertura vegetal fotosintéticamente activa) [92]. Teniendo en cuenta que la disponibilidad de imágenes ópticas suele estar limitada por la interferencia de las nubes y la neblina sobre el área de estudio, esta limitación fue superada con el uso de imágenes radar que no se ven afectadas por estos factores. Donde los datos SAR usados para la clasificación de pastizales obtuvieron mejores resultados que los datos ópticos.

Se requirió una menor cantidad de escenas provenientes de datos ópticos para lograr una precisión de clasificación relevante en comparación al conjunto de imágenes de radar adquiridas. Pero, no solo el análisis óptico de la información proveniente del verdor y brillo de la vegetación, sino también los parámetros morfológicos estructurales medidos a partir de las imágenes radar son indicativos de las composiciones vegetales de los pastizales [18]. Por lo cual, se sugiere evaluar diferentes alternativas de análisis sinérgico para explotar las ventajas complementarias entre los datos ópticos y SAR, y así, obtener una descripción más completa de las características de las coberturas vegetales y lograr reducir imprecisiones y errores de clasificación, conduciendo a resultados de mayor calidad [22].

Referencias bibliográficas

- [1] K. Voormansik, T. Jagdhuber, K. Zalite, M. Noorma, y I. Hajnsek, “Observations of Cutting Practices in Agricultural Grasslands Using Polarimetric SAR,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, pp. 1382–1396, 04 2016.
- [2] E. Zillmann, A. Gonzalez, E. J. Montero-Herrero, J. van Wavelaer, T. Esch, M. Keil, H. Weichelt, y A. M. Garzón, “Pan-European Grassland Mapping Using Seasonal Statistics From Multisensor Image Time Series,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, pp. 3461–3472, 08 2014.
- [3] E. Zillmann, H. Weichelt, E. M. Herrero, T. Esch, M. Keil, y J. van Wavelaer, “Mapping of grassland using seasonal statistics derived from multi-temporal satellite images,” in *MultiTemp 2013: 7th International Workshop on the Analysis of Multi-temporal Remote Sensing Images*, pp. 1–3, 06 2013.
- [4] R. Siegmund, K. Grant, M. Wagner, y S. Hartmann, “Satellite-based monitoring of grassland: assessment of harvest dates and frequency using SAR,” p. 999803, 10 2016.
- [5] M. Cristiano Piedad, *Estimación de la productividad primaria mediante el modelo de eficiencias y sensores remotos*. PhD thesis, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Argentina, 2010.
- [6] M. M. García, *Estimación de la biomasa aérea de herbáceas con sensores aerotransportados de alta resolución*. PhD thesis, Universidad de León. España, 2016.
- [7] L. J. Blanco, M. Durante, D. Ferrante, R. E. Quiroga, M. R. Demaria y C. M. Di Bella, “Red nacional de monitoreo de pastizales naturales de Argentina: productividad forrajera de la vegetación extrapampeana,” *Instituto Nacional de Tecnología Agropecuaria*, vol. 45, 05 2019.
- [8] J. Bengtsson, J. Bullock, B. Egoh, C. Everson, T. Everson, T. O’Connor, P. O’Farrell, H. Smith y R. Lindborg, “Grasslands—more important for ecosystem services than you might think,” *Ecosphere*, vol. 10, 02 2019.
- [9] G. Pineiro, J. M. Paruelo y M. Oesterheld, “Potential long-term impacts of livestock introduction on carbon and nitrogen cycling in grasslands of Southern South America,” *Global Change Biology*, vol. 12, no. 7, pp. 1267–1284, 2006.
- [10] E. Jobbágy, M. Vasallo, K. Farley, G. Piñeiro, M. Garbulsy, M. Noretto, R. Jackson, y J. Paruelo, “Forestación En Pastizales : Hacia Una Visión Integral De Sus Oportunidades Y Costos Ecológicos,” *Agrociencia*, vol. X, no. 2, pp. 109–124, 2006.

- [11] G. Han, X. Hao, M. Zhao, M. Wang, B. Ellert, W. Willms, y M. Wang, “Effect of grazing intensity on carbon and nitrogen in soil and vegetation in a meadow steppe in Inner Mongolia,” *Agriculture, Ecosystems & Environment*, vol. 125, no. 1-4, pp. 21–32, 2008.
- [12] O. Chiossone . Sitio argentino de producción animal, “Pastizales naturales de Argentina.” <http://www.produccion-animal.com.ar/>. EEA INTA El Colorado, Formosa. Último acceso en febrero de 2021.
- [13] G. García-Martínez, G. Irisarri, y R. Golluscio, “Uso de un sistema de seguimiento forrajero basado en imágenes satelitales,” pp. 171–174, 2010.
- [14] CREA, “Pautas para el manejo reproductivo en rodeos de cría. Informe técnico de ganadería,” Tech. Rep. 3, 2019.
- [15] I. Ali, F. Cawkwell, E. Dwyer, B. Barrett, y S. Green, “Satellite remote sensing of grasslands: from observation to management,” *Journal of Plant Ecology*, vol. 9, pp. 649–671, 02 2016.
- [16] Z. Li y X. Guo, “Can Polarimetric Radarsat-2 Images Provide a Solution to Quantify Non-Photosynthetic Vegetation Biomass in Semiarid Mixed Grassland?,” *Canadian Journal of Remote Sensing*, vol. 43, no. 6, pp. 593–607, 2017.
- [17] F. Charbonneau, M. Trudel y R. Fernandes, “Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping,” in *Proceedings of the 2005 Advanced Synthetic Aperture Radar (ASAR) Workshop, St-Hubert, QC, Canada*, pp. 15–17, 2005.
- [18] C. Schuster, T. Schmidt, C. Conrad, B. Kleinschmit y M. Förster, “Grassland Habitat Mapping by Intra-Annual Time Series Analysis - Comparison of RapidEye and TerraSAR-X Satellite Data,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 34, pp. 25–34, 02 2015.
- [19] S. Baeza, J. Paruelo y F. Lezama, *Caracterización funcional en pastizales y sus aplicaciones en Uruguay*, pp. 163–182. 01 2011.
- [20] L. Zhong, P. Gong y G. Biging, “Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery,” *Remote Sensing of Environment*, vol. 140, p. 1–13, 01 2014.
- [21] A. K. Shakya, A. Ramola, K. Sawant y A. Kandwal, “Comparison of Supervised Classification Techniques for High-Resolution Optical Aerial Image,” pp. 139–144, 10 2018.
- [22] M. J. Hill, C. J. Ticehurst, L. Jong-Sen, M. R. Grunes, G. E. Donald, y D. Henry, “Integration of optical and radar classifications for mapping pasture type in Western Australia,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 1665–1681, 07 2005.
- [23] G. Hong, A. Zhang, F. Zhou, y B. Brisco, “Integration of optical and synthetic aperture radar (SAR) images to differentiate grassland and alfalfa in Prairie area,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 28, no. 1, pp. 12–19, 2014.

- [24] C. Qiao, B. Daneshfar, A. Davidson, I. Jarvis, T. Liu, y T. Fiset, “Integration of optical and polarimetric SAR imagery for locally accurate crop classification,” in *2014 IEEE Geoscience and Remote Sensing Symposium*, pp. 1485–1488, 07 2014.
- [25] C. Raab, H. G. Stroh, B. Tonn, M. Meißner, N. Rohwer, N. Balkenhol, y J. Isselstein, “Mapping semi-natural grassland communities using multi-temporal RapidEye remote sensing data,” *International Journal of Remote Sensing*, vol. 39, no. 17, pp. 5638–5659, 2018.
- [26] A. Cerutti, N. Mónaco, M. J. Rosa, y V. Santa, “Relación entre biomasa aérea y producción primaria neta con las variaciones estacionales de precipitaciones y temperaturas en pastizales del sur de la provincia de Córdoba,” *European Scientific Journal, ESJ*, vol. 13, no. 5, pp. 117–133, 2017.
- [27] S. Ullah, Y. Si, M. Schlerf, A. K. Skidmore, M. Shafique y I. A. Iqbal, “Estimation of grassland biomass and nitrogen using MERIS data,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 19, pp. 196–204, 2012.
- [28] B. Zhang, L. Zhang, D. Xie, X. Yin, C. Liu, y G. Liu, “Application of Synthetic NDVI Time Series Blended from Landsat and MODIS Data for Grassland Biomass Estimation,” *Remote Sensing*, vol. 8, no. 1, 2016.
- [29] I. Ali, F. Cawkwell, E. Dwyer, y S. Green, “Modeling Managed Grassland Biomass Estimation by Using Multitemporal Remote Sensing Data—A Machine Learning Approach,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, pp. 3254–3264, 07 2017.
- [30] X. Yang, B. Xu, Y. Jin, J. Li, y X. Zhu, “On grass yield remote sensing estimation models of China’s northern farming-pastoral ecotone,” *Advances in Intelligent and Soft Computing*, vol. 141 AISC, pp. 281–291, 2012.
- [31] Y. Xie, Z. Sha, M. Yu, Y. Bai, y L. Zhang, “A comparison of two models with Landsat data for estimating above ground grassland biomass in Inner Mongolia, China,” *Ecological Modelling*, vol. 220, pp. 1810–1818, 08 2009.
- [32] O. Reisi-Gahrouei, S. Homayouni, H. McNairn, M. Hosseini, y A. Safari, “Crop biomass estimation using multi regression analysis and neural networks from multitemporal L-band polarimetric synthetic aperture radar data,” *International Journal of Remote Sensing*, pp. 1–19, 03 2019.
- [33] R. D’Andrimont, G. Lemoine, y M. Van der Velde, “Targeted Grassland Monitoring at Parcel Level Using Sentinels, Street-Level Images and Field Observations,” *Remote Sensing*, vol. 10, no. 8, 2018.
- [34] L. Stendardi, S. R. Karlsen, G. Niedrist, R. Gerdol, M. Zebisch, M. Rossi, y C. Notarnicola, “Exploiting time series of Sentinel-1 and Sentinel-2 imagery to detect meadow phenology in mountain regions,” *Remote Sensing*, vol. 11, no. 5, pp. 1–24, 2019.
- [35] L. Prévot, I. Champion, y G. Guyot, “Estimating surface soil moisture and leaf area index of a wheat canopy using a dual-frequency (C and X bands) scatterometer,” *Remote Sensing of Environment*, vol. 46, pp. 331–339, 12 1993.

- [36] J. Krishnaswamy, K. Bawa, K N, Ganeshaiyah y K. Chandrasekharan, “Quantifying and mapping biodiversity and ecosystem services: Utility of a multi-season NDVI based Mahalanobis distance surrogate,” *Remote Sensing of Environment - REMOTE SENS ENVIRON*, vol. 113, pp. 857–867, 04 2009.
- [37] A. Smith y J. Buckley, “Investigating RADARSAT-2 as a tool for monitoring grassland in western Canada,” *Canadian Journal of Remote Sensing*, vol. 37, pp. 93–102, 02 2011.
- [38] A. Freeman, y S.L. Durden, “A three-component scattering model for polarimetric SAR data,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 3, pp. 963–973, 1998.
- [39] T. Whelen y P. Siqueira, “Time-series classification of Sentinel-1 agricultural data over North Dakota,” *Remote Sensing Letters*, vol. 9, pp. 411–420, 05 2018.
- [40] E. Chuvieco, *Teledetección Ambiental: La observación de la Tierra desde el Espacio*. Editorial Ariel, 2006.
- [41] M. Nolasco, “Mapeo remoto multisensor de coberturas agrícolas extensivas en la zona central de Córdoba,” Master’s thesis, Maestría en Aplicaciones de Información Espacial (MAIE). Córdoba, Argentina, 2018.
- [42] R. Chowhan y P. Dayya, “Sustainable Smart Farming for Masses Using Modern Ways of Internet of Things (IoT) Into Agriculture,” pp. 189–219, 01 2019.
- [43] J. Gabás-Masip, “Maxwell: la teoría electromagnética de la luz,” *Arbor*, vol. 191, no. 775, p. a265, 2015.
- [44] J. R. Jensen, *Remote sensing of the environment: an earth resource perspective- Second Edition*. Pearson Education, 2014.
- [45] A. Huete, *Remote Sensing for Environmental Monitoring*, pp. 183–206. Burlington: Academic Press, 12 2004.
- [46] B. Stephanie, “Roof Surface Classification with Hyperspectral and Laser Scanning Data - An Assessment of Spectral Angle Mapper and Support Vector Machines,” 2012.
- [47] I. G. Pascual, “Clasificación de áreas sembradas y determinación del momento de cosecha en Caña de azúcar y Pastizales mediante imágenes ópticas y SAR,” Master’s thesis, Maestría en Aplicaciones de Información Espacial (MAIE). Córdoba, Argentina, 2018.
- [48] R. Solorza, “Estimación de la humedad superficial del suelo mediante el uso combinado de modelos electromagnéticos y el enfoque bayesiano. Estudio exploratorio en imágenes SARAT,” Master’s thesis, Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias (AEARTE). Córdoba, Argentina, 2013.
- [49] ESA. European Space Agency, “Sentinel User Guides.” <https://sentinels.copernicus.eu/web/sentinel/home>. Último acceso en junio de 2019.
- [50] A. J. Zozaya, “Reporte Técnico. Diseño de radares de apertura sintética,” *Instituto Espacial Ecuatoriano*, pp. 1–37, 2015.

- [51] Globe SAR, “Material Educativo para Teledetección mediante Radares,” *GlobeSAR Program Canada Centre for Remote Sensing*, p. 966, 2005.
- [52] D. M. Maldonado Nievas, “Sistema de generación de imágenes mediante RADAR,” *Escuela de Ingeniería Eléctrica Facultad de Ingeniería de Valparaíso, Chile*, 2018.
- [53] A. Flores, K. Herndon, R. Thapa, y E. Cherrington, *The SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. 04 2019.
- [54] J. R. Jensen, *Remote Sensing of the Environment: An Earth Resource Perspective*, vol. 16. 01 2000.
- [55] CONAE. Comisión Nacional de Actividades Espaciales, “Misiones Satelitales - SAO-COM.” <https://www.argentina.gob.ar/ciencia/conae>. Último acceso en febrero de 2021.
- [56] A. Sekertekin, A. Marangoz, S. Abdikan, y M. Esetlili, “preliminary results of estimating soil moisture over bare soil using full-polarimetric ALOS-2 data,” vol. XLII-2/W1, 10 2016.
- [57] N. Baghdadi, M. El Hajj, M. Zribi, y S. Bousbih, “Calibration of the water cloud model at c-band for winter crop fields and grasslands,” *Remote Sensing*, vol. 9, p. 13, 09 2017.
- [58] M. El Hajj, N. Baghdadi, M. Zribi, G. Belaud, B. Cheviron, D. Courault, y F. Charron, “Soil moisture retrieval over irrigated grassland using X-band SAR data,” *Remote Sensing of Environment*, vol. 176, pp. 202–218, 2016.
- [59] J. Awange y J. Kiema, *Microwave Remote Sensing*. Cham: Springer International Publishing, 2019.
- [60] R. Sabattini, M. Wilson, N. Muzzachiodi, y A. Dorsch, “Guía para la caracterización de agroecosistemas del centro-norte de Entre Ríos,” *Científica Agropecuaria*, vol. 3, pp. 7–19, 1999.
- [61] QGIS Development Team, *QGIS Geographic Information System*. Open Source Geospatial Foundation, 2009.
- [62] A. Rojas y J. Saluso, “Informe climático de la Provincia de Entre Ríos,” *Publicación técnica*, vol. 14, 1987.
- [63] O. Paparotti, y J. Gvozdenovich, “Caracterización de zonas y subzonas RIAP Entre Ríos. RIAN-RIAP Centro Regional Entre Ríos, INTA. 26 p,” 2007.
- [64] N. Hein y M. Purnell, “Los suelos de la Estación Experimental Agropecuaria Concepción del Uruguay, Provincia de Entre Ríos,” *INTA*, vol. 43, 1974.
- [65] Plan Mapa de Suelos Provincia de Entre Ríos, “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*, p. 109, 1980.
- [66] F. Isotta, C. Frei, V. Weigluni, M. Perčec Tadić, P. Lassegues, B. Rudolf, V. Pavan, C. Cacciamani, G. Antolini, S. Ratto, M. Munari, S. Micheletti, V. Bonati, C. Lussana, C. Ronchi, E. Panettieri, G. Marigo, y G. Vertačnik, “The climate of daily precipitation in the Alps: Development and analysis of a high-resolution grid dataset from pan-Alpine rain-gauge data,” *International Journal of Climatology*, vol. 34, pp. n/a–n/a, 04 2014.

- [67] J. Petelka, B. Plagg, I. Säumel, y S. Zerbe, “Traditional medicinal plants in South Tyrol (Northern Italy, Southern Alps) – biodiversity and use,” 06 2020.
- [68] Eurac Research Institute for Alpine Environment, “Biodiversity monitoring.” <https://biodiversity.eurac.edu/research-sites/>. Access to pastures and meadows. Último acceso en marzo de 2022.
- [69] European Space Agency, “Sentinel-1 User Handbook,” vol. 2, no. GMES-S1OP-EOPG-TN-13-0001, pp. 31–38, 2013.
- [70] USGS. United States Geological Survey, “Earth Explorer.” <https://earthexplorer.usgs.gov/>. Último acceso en mayo de 2019.
- [71] L. Lezana, M. Durante, S. Boffa, J. Fonseca, S. Canavelli, A. Kemerer, N. Calamari, A. Wingeyer, y M. Bordagaray, “Intensidad de pastoreo en predios ganaderos de cría del espinal entrerriano,” no. 1, p. 88, 2017.
- [72] M. Rossi, G. Niedrist, S. Asam, G. Tonon, E. Tomelleri, y M. Zebisch, “A comparison of the signal from diverse optical sensors for monitoring alpine grassland dynamics,” *Remote Sensing*, vol. 11, 2019.
- [73] L. Frulla, J. Milovich, H. Karszenbaum, y P. Kandus, “Metodologías de pre-procesamiento y procesamiento utilizadas en el tratamiento cuantitativo de datos SAR para el estudio de ambientes en el bajo delta Río Paraná, Argentina,” *Consejo nacional de Investigaciones Científicas y Técnicas (CONICET)*, 1998.
- [74] L. Veci, “SENTINEL-1 Toolbox-SAR Basics Tutorial,” *Proceedings of the National Academy of Sciences*, vol. 114, no. 4, pp. S1–S4, 2015.
- [75] J. W. Park, A. Korosov, M. Babiker, S. Sandven, y J. S. Won, “Efficient Thermal Noise Removal for Sentinel-1 TOPSAR Cross-Polarization Channel,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. PP, pp. 1–11, 12 2017.
- [76] C. Winship y R. Mare, “Regression Models with Ordinal Variables,” *American Sociological Review*, vol. 49, p. 512, 08 1984.
- [77] M. E. Szretter Noste, “Apunte de Regresión Lineal - Carrera de Especialización en Estadística Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires,” p. 249, 10 2013.
- [78] B. Warner, y M. Misra, “Understanding neural networks as statistical tools,” *The American Statistician*, vol. 50, 02 1970.
- [79] R. A. Johnson y D. W. Wichern, *Applied multivariate statistical analysis*, vol. 5. Prentice hall Upper Saddle River, NJ, 2002.
- [80] B. L. Carvacho y M. Sánchez-Martínez, “Comparación de índices de vegetación a partir de imágenes MODIS en la región del Libertador Bernardo O’Giggins, Chile, en el período 2001-2005,” *Age.Ieg.Csic.Es*, pp. 728–737, 2010.
- [81] J. Días García-Cervigón, “Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión,” Master’s thesis, Universidad Complutense de Madrid, España, 2015.

- [82] M. Bolaños-González y F. Paz-Pellat, “Modelación general de los efectos de la geometría de iluminación-visión en la reflectancia de pastizales,” *Revista mexicana de ciencias pecuarias*, vol. 1, pp. 349–361, 12 2010.
- [83] A. Veloso, S. Mermoz, A. Bouvet, T. Le Toan, M. Planells, J. F. Dejoux, y E. Ceschia, “Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications,” *Remote Sensing of Environment*, vol. 199, pp. 415–426, 09 2017.
- [84] INTA, “Sistema de Información y Gestión Agrometeorológica. Nuevo Sitio Web SIGA.” <http://sig2.inta.gov.ar/#/>. Último acceso en agosto de 2020.
- [85] Agenzia per la protezione civile, “Servizi web delle misurazioni meteo e idrografiche.” <http://daten.buergernetz.bz.it/dataset/misure-meteo-e-idrografiche>. Open Data del Súd Tirol Alto Adige. Último acceso en marzo de 2020.
- [86] M. C. Dobson, L. Pierce, K. McDonald, y T. Sharik, “Seasonal change in radar backscatter from mixed conifer and hardwood forests in northern Michigan,” in *[Proceedings] IGARSS’91 Remote Sensing: Global Monitoring for Earth Management*, vol. 3, pp. 1121–1124, 1991.
- [87] P. Dusseux, T. Corpetti, L. Hubert-Moy, y S. Corgne, “Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring,” *Remote Sensing*, vol. 6, pp. 6163–6182, 07 2014.
- [88] V. Reinoso, y C. Soto, “Cálculo y manejo en pastoreo controlado. Nivel de oferta forrajera y utilización de la pastura,” pp. 41–161, 06 2006.
- [89] J. Borràs, J. Delegido, A. Pezzola, M. Pereira, G. Morassi, y G. Camps-Valls, “Clasificación de usos del suelo a partir de imágenes Sentinel-2,” *Revista de Teledetección*, vol. 2017, p. 55, 06 2017.
- [90] H. Zakeri, F. Yamazaki, y W. Liu, “Texture analysis and land cover classification of Tehran using Polarimetric Synthetic Aperture Radar Imagery,” *Applied Sciences*, vol. 7, p. 452, 04 2017.
- [91] A. Cortés Murcia y A. Herrera, *Elaboración de mapas de uso y cobertura con sistemas de radar*. PhD thesis, Universidad Distrital Francisco José de Caldas. Bogotá, D.C, 03 2011.
- [92] T. Schmidt, C. Schuster, B. Kleinschmit, y M. Förster, “Evaluating an Intra-Annual Time Series for Grassland Classification—How Many Acquisitions and What Seasonal Origin Are Optimal?,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, pp. 3428–3439, 08 2014.
- [93] ENVI, *ENVI Tutorial: Classification Methods*. Boulder, Colorado: Exelis Visual Information Solutions, 2010.
- [94] A. L. Manzán, L. Pagliettini, y D. Robles, “Valoración del agua para la producción de arroz en Entre Ríos. Valuation of water for rice production in Entre Ríos,” *Aqua-LAC*, vol. 4, no. 1, pp. 1–8, 2012.

- [95] L3 Harris Geospatial Documentation Center. Region of Interest (ROI) Tool. <https://www.harrisgeospatial.com/docs/RegionOfInterestTool.html#SaveROIs>. Último acceso en septiembre de 2019.
- [96] Z. Li, *Quantifying Grassland Non-Photosynthetic Vegetation Biomass Using Remote Sensing Data*. PhD thesis, University of Saskatchewan Saskatoon, Canadá, 2017.
- [97] K. Hergoualc'h, V. Gutierrez Velez, M. Menton, y L. Verchot, *Caracterización de la degradación de los pantanos de palmeras turbosos desde el espacio y sobre el terreno: Un estudio exploratorio en la Amazonia peruana*, vol. 179. CIFOR, 2017.
- [98] Unidad Ejecutora 001631: Gestión de Proyectos Sectoriales - UEGPS, “Metodología para la clasificación de coberturas a partir del procesamiento de imágenes satelitales,” *Ministerio de Agricultura y Riego*, no. 1, pp. 64–65, 2018.
- [99] Y. Jin, X. Yang, J. Qiu, J. Li, T. Gao, Q. Wu, F. Zhao, H. Ma, H. Yu, y B. Xu, “Remote sensing-based biomass estimation and its spatio-temporal variations in temperate Grassland, Northern China,” *Remote Sensing*, vol. 6, no. 2, pp. 1496–1513, 2014.
- [100] O. Mutanga y A. Skidmore, “Narrow band vegetation indices overcome the saturation problem in biomass estimation,” *International Journal of Remote Sensing*, vol. 25, pp. 3999–4014, 10 2004.
- [101] L. Vescovo, G. Wohlfahrt, M. Balzarolo, S. Pilloni, M. Sottocornola, M. Rodeghiero, y D. Gianelle, “New spectral vegetation indices based on the near-infrared shoulder wavelengths for remote detection of grassland phytomass,” *International journal of remote sensing*, vol. 33, 04 2012.
- [102] M. M. Hanna, D. A. Steyn-Ross, y M. Steyn-Ross, “Estimating Biomass for New Zealand Pasture Using Optical Remote Sensing Techniques,” *Geocarto International*, vol. 14, no. 3, pp. 89–94, 1999.
- [103] A. Vila, M. Sedano, A. López, y A. Juan, “Correlación lineal y análisis de regresión,” *Barcelona: Universidad Oberta de Catalunya*, 2004.
- [104] E.S. Flynn, “Using NDVI as a pasture management tool,” Master’s thesis, University of Kentucky. Lexington, Estados Unidos, 2006.
- [105] N. Nuthammachot, A. Askar, D. Stratoulis, y P. Wicaksono, “Combined use of Sentinel-1 and Sentinel-2 data for improving above-ground biomass estimation,” *Geocarto International*, pp. 1–11, 02 2020.
- [106] C. Finnigan, “Developing a Grassland Biomass Monitoring Tool Using a Time Series of Dual Polarimetric SAR and Optical Data,” 2013.
- [107] F. Gallego, F. Lezama, F. Pezzani, L. López-Mársico, E. Leoni, A. Mello, y B. Costa, “Estimación de la productividad primaria neta aérea y capacidad de carga ganadera: un estudio de caso en Sierras del Este, Uruguay,” *Agrociencia*, vol. 21, pp. 120–130, 06 2017.
- [108] M. Foncin, “Vegetation Maps,” *The Geographical Journal*, vol. 126, no. 4, p. 552, 1960.

- [109] M. Vreugdenhil, W. Wagner, B. Bauer-Marschallinger, I. Pfeil, I. Teubner, C. Rüdiger y P. Strauss, “Sensitivity of Sentinel-1 backscatter to vegetation dynamics: An Austrian case study,” *Remote Sensing*, vol. 10, no. 9, p. 1396, 2018.
- [110] A. Taravat, M. P. Wagner y N. Oppelt, “Automatic Grassland Cutting Status Detection in the Context of Spatiotemporal Sentinel-1 Imagery Analysis and Artificial Neural Networks,” *Remote Sensing*, vol. 11, no. 6, 2019.
- [111] R. Zinda y L. Carreño, *Estado actual del Bosque Nativo Pampeano: Tipos fisonómicos de vegetación - EEA INTA Anguil.* 08 2018.
- [112] L. Tiangang, Y. Shuxia, F. Qisheng, L. Baokang, Z. Renping, H. Xiaodong, y X. Hongjie, “Multi-factor modeling of above-ground biomass in alpine grassland: A case study in the Three-River Headwaters Region, China,” *Remote Sensing of Environment*, vol. 186, pp. 164 – 172, 2016.
- [113] B. Warner y M. Misra, “Understanding Neural Networks as Statistical Tools,” *The American Statistician*, vol. 50, no. 4, pp. 284–293, 1996.

Anexos

Anexo A

Listado de todas las imágenes satelitales utilizadas en el área de estudio: Entre Ríos

Tabla A.1: Descripción de las imágenes S-1 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina

Nº de imagen	Fecha de adquisición	Dirección de órbita	Modo de adquisición	Nivel de procesamiento	Polarización	Orbita relativa	Frame	Proyección/Datum
1	2/2/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
2	8/3/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
3	14/4/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
4	28/4/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
5	24/6/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
6	9/8/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
7	5/9/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
8	5/10/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
9	17/10/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
10	29/10/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
11	10/11/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
12	22/11/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
13	4/12/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
14	16/12/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
15	28/12/2016	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
16	9/1/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
17	21/1/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
18	2/2/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
19	14/2/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
20	26/2/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
21	10/3/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
22	3/4/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
23	15/4/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
24	27/4/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
25	9/5/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
26	21/5/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
27	2/6/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
28	14/6/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
29	26/6/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84

**A LISTADO DE TODAS LAS IMÁGENES SATELITALES
UTILIZADAS EN EL ÁREA DE ESTUDIO: ENTRE RÍOS**

N° de imagen	Fecha de adquisición	Dirección de órbita	Modo de adquisición	Nivel de procesamiento	Polarización	Orbita relativa	Frame	Proyección/Datum
30	20/7/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
31	1/8/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
32	13/8/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
33	25/8/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
34	6/9/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
35	18/9/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
36	12/10/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
37	24/10/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
38	5/11/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
39	17/11/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
40	29/11/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
41	11/12/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
42	23/12/2017	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
43	4/1/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
44	16/1/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
45	28/1/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
46	9/2/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
47	21/2/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
48	5/3/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
49	17/3/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
50	29/3/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
51	10/4/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
52	22/4/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
53	4/5/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
54	16/5/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
55	28/5/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
56	9/6/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
57	21/6/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
58	3/7/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
59	15/7/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
60	27/7/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
61	8/8/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
62	20/8/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
63	1/9/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
64	13/9/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
65	25/9/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
67	7/10/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
68	19/10/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84
69	31/10/2018	Descending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	68	702	UTM (zona 21S)/WGS-84

A LISTADO DE TODAS LAS IMÁGENES SATELITALES
UTILIZADAS EN EL ÁREA DE ESTUDIO: ENTRE RÍOS

Tabla A.2: Descripción de las imágenes S-2 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina

Nº de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Órbita relativa	Identificador de mosaico	Proyección/Datum
1	20/1/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
2	30/3/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
3	8/6/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
4	18/6/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
5	18/7/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
6	7/8/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
7	17/8/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
8	26/9/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
9	25/11/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
10	5/12/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
11	15/12/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
12	24/1/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
13	23/2/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
14	24/4/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
15	13/7/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
16	17/8/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
17	30/11/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
18	15/12/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
19	20/12/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
20	25/12/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
21	4/1/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
22	9/1/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
23	3/2/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
24	23/2/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
25	10/3/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
26	20/3/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
27	14/4/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
28	24/5/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
29	2/8/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
30	12/8/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
31	22/8/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
32	6/9/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
33	11/9/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
34	21/10/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84

A LISTADO DE TODAS LAS IMÁGENES SATELITALES
UTILIZADAS EN EL ÁREA DE ESTUDIO: ENTRE RÍOS

Tabla A.3: Descripción de las imágenes L-8 utilizadas en el área de estudio de la región centro-sur de Entre Ríos, Argentina

N° de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Path	Row	Proyección/Datum
1	23/1/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
2	11/3/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
3	18/8/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
4	19/9/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
5	6/11/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
6	22/11/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
7	14/3/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
8	1/5/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
9	17/5/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
10	4/7/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
11	20/7/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
12	5/8/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
13	21/8/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
14	8/10/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
15	9/11/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
16	25/11/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
17	11/12/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
18	27/12/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
19	13/2/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
20	1/3/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
21	18/4/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
22	21/6/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
23	9/9/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
24	27/10/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84

Anexo B

Listado de todas las imágenes ópticas descartadas por presencia de nubes

Tabla B.1: Descripción de las imágenes S-2 correspondientes al área de estudio de la región centro-sur de Entre Ríos (Argentina) descartadas por presencia de nubes

Nº de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Orbita relativa	Identificador de mosaico	Proyección/Datum
1	05/02/2015	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
2	29/04/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
3	28/07/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
4	06/10/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
5	15/11/2016	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
6	04/04/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
7	11/09/2017	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
8	30/03/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
9	09/04/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
10	03/06/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84
11	08/06/2018	10/20/60 metros	LIC (TOA Reflectance)	24	21HUE	UTM (zona 21S)/WGS-84

Tabla B.2: Descripción de las imágenes L-8 correspondientes al área de estudio de la región centro-sur de Entre Ríos (Argentina) descartadas por presencia de nubes

Nº de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Path	Row	Proyección/Datum
1	05/02/2015	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
2	15/06/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
3	17/07/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
4	24/12/2016	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
5	25/01/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
6	18/06/2017	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84
7	28/01/2018	30 metros	L1TP (Land Surface Reflectance)	225	83	UTM (zona 21S)/WGS-84

Anexo C

Listado de todas las imágenes satelitales utilizadas en el área de estudio: Val Mazia

Tabla C.1: Descripción de las imágenes S-1 utilizadas en el área de estudio de la región de Val Mazia, Italia

Nº de imagen	Fecha de adquisición	Dirección de órbita	Modo de adquisición	Nivel de procesamiento	Polarización	Orbita relativa	Frame	Proyección/Datum
1	24/5/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
2	30/5/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
3	5/6/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
4	11/6/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
5	17/6/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
6	23/6/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
7	29/6/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
8	5/7/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
9	11/7/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
10	17/7/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
11	23/7/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
12	29/7/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
13	4/8/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
14	10/8/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
15	16/8/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
16	22/8/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
17	28/8/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
18	3/9/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
19	9/9/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
20	15/9/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
21	21/9/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
22	27/9/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
23	3/10/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
24	9/10/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84
25	15/10/2017	Ascending	Interferometric Wide Swath (IW)	Ground Range Detected (GRD)	VV-VH	117	148	UTM (zona 32N)/WGS-84

C LISTADO DE TODAS LAS IMÁGENES SATELITALES
UTILIZADAS EN EL ÁREA DE ESTUDIO: VAL MAZIA

Tabla C.2: Descripción de las imágenes S-2 utilizadas en el área de estudio de la región de Val Mazia, Italia

Nº de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Órbita relativa	Identificador de mosaico	Proyección/Datum
1	17/5/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
2	26/5/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
3	23/6/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
4	27/6/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
5	15/7/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
6	20/8/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
7	21/9/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84
8	11/10/2017	10/20/60 metros	L1C (TOA Reflectance)	65	32TPS	UTM (zona 32N)/WGS-84

Tabla C.3: Descripción de las imágenes L-8 utilizadas en el área de estudio de la región de Val Mazia, Italia

Nº de imagen	Fecha de adquisición	Resolución espacial	Nivel de procesamiento	Path	Row	Proyección/Datum
1	17/5/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84
2	2/6/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84
3	18/6/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84
4	4/7/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84
5	5/8/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84
6	22/9/2017	30 metros	L1TP (Land Surface Reflectance)	193	28	UTM (zona 32N)/WGS-84

Anexo D

Script utilizado para el cálculo de las regresiones y análisis de supuestos de normalidad (Argentina e Italia)

```
###Script para el cálculo de las regresiones lineales y múltiples, y el análisis de los supuestos.
rm(list=ls())
setwd('C:/Users/Documents/R')#cargar directorio de trabajo donde se disponen de los datos .csv

#####Librerias#####
# 1) Librerias
library(stats) # ANOVA y Gráfico de NO-Interacción Bloque-Factor
library(agricolae) # Procedimientos estadísticos para la investigación agrícola (Tukey)
library(gplots) # Gráfico de Medias y Desvíos
library(graphics) # Gráfico de Dispersion
library(car) # Contiene funciones para la regresión
library(Hmisc) # Funciones útiles para el análisis de datos

#####CargoBases#####
# 2) Carga de Datos de SAR u ópticos para el cálculo de Regresión Lineal Simple.
MI_ARCHIVO <- c("SARSitio1.csv")#SARSitio1 #SARSitio2 #OPTICOSitio1 #OPTICOSitio2(Entre Ríos) #SARBolzano #OPTICOBolzano(Val Mazi
BASE <- read.csv(file = MI_ARCHIVO, sep = ";", dec = ".", header = T)

# 3) Aislamiento de las variables a utilizar.
### Identificamos el número de columna de la variable respuesta y de la variable independiente
NUM_COL_VR <- 3 #Biomasa de los pastizales
NUM_COL_VI <- 1 #1:VH 2:VH/VV (En el caso de datos SAR para Entre Ríos) #1:VH 2:VV (En el caso de datos SAR para Bolzano)
#1:NDVI (En el caso de datos ópticos para Entre Ríos) #1:NDVI (En el caso de datos ópticos para Bolzano)

### Creamos un vector con los dos objetos seleccionados.
### El nuevo vector contiene el Número de las Columnas Seleccionadas que ingresarán en el análisis de Regresión Lineal Simple.
NUM_COL_SEL <- c(NUM_COL_VR, NUM_COL_VI)
### Creamos una MINIBASE de datos (MINIBASE será un objeto que contiene solo las variables (columnas) que ingresan al análisis).
MINIBASE <- BASE[, NUM_COL_SEL]
### Limpiamos la MINIBASE de aquellos datos faltantes (celdas vacías).
### Nos quedan todas las filas que tienen datos completos para el análisis.
MINIBASE <- na.omit(MINIBASE)
### Creamos dos objetos... 'VR' y 'VI'.
VR <- MINIBASE[,1]
VI <- MINIBASE[,2]
### Verificamos la validez de argumentos para funciones numéricas.
is.numeric(VR)
is.numeric(VI)

# 4) Generación de resultados y gráficos
### Crearemos un objeto llamado 'LM' que contendrá todos los cálculos realizados por R para un Modelo Lineal General.
LM <- lm(VR ~ VI)
REGRESION <- summary(LM)
### Pedimos ahora el Gráfico de Dispersion con la recta ajustada
plot.new() ### Creamos un plot vacío
rect(par("usr")[1], par("usr")[3], par("usr")[2], par("usr")[4], col = "gray") ### Coloreamos la caja
par(new = TRUE)
### Incorporamos los elementos del gráfico
plot(VI, VR, main = "Relación entre el Coeficiente de retrodispersión (VH) y la biomasa de los pastizales ('Sitio 1')",
xlab = "Coeficiente de retrodispersión (VH)", ylab = "Biomasa promedio (KgMS/Ha)",
cex = 1, cex.main = 1, cex.lab = 0.8, cex.axis = 0.75, font.main = 2, font.lab = 2, col = "blue", bg = "blue", pch = 16,
panel.first=grid(VI,NULL, lty = 1, col = "lightgray"), xlim=c(-12, -5), ylim=c(-50, 2500), las=1,
text(x = -3.9, y = 1250, label = "R²=0,51", col = "black", font = 2, xpd=TRUE))
minor.tick(nx=4, ny=4, tick.ratio=0.3, x.args = list(), y.args = list())
abline(LM, col="blue", lwd = 2, lty = 3)
### Ya tenemos realizado el análisis de Regresión Lineal Simple, si bien ya tenemos la 'REGRESION' con los dos valores p.,
### toda interpretación que hagamos solo es válida si los errores son estadísticamente NORMALES y HOMOGENEOS.
### Creamos un nuevo objeto llamado 'RESIDUOS'
RESIDUOS <- LM$residuals
### Estos 'RESIDUOS' ingresarán al test de Shapiro-Wilks y al Gráfico para observar la Homogeneidad de Varianzas de los errores.
### NORMALIDAD DE LOS ERRORES (Test de Shapiro-Wilks)
SHAPIRO <- shapiro.test(RESIDUOS)
```

D SCRIPT UTILIZADO PARA EL CÁLCULO DE LAS REGRESIONES Y ANÁLISIS DE SUPUESTOS DE NORMALIDAD (ARGENTINA E ITALIA)

```
### HOMOGENEIDAD DE VARIANZAS DE LOS ERRORES
### Ya tenemos los 'RESIDUOS'. Ahora aislamos los predichos, los residuos estudentizados y los valores Leverage de cada dato.
PREDICHOS <- LM$fitted.values
RESIDUOS_ESTUDENTIZADOS <- rstudent(LM)
COOK <- cooks.distance(LM)

### Gráfico y detección para 'PREDICHOS' vs 'RESIDUOS'
plot.new() ### Creamos un plot vacío
rect(par("usr")[1], par("usr")[3], par("usr")[2], par("usr")[4], col = "gray") ### Coloreamos la caja
par(new = TRUE)
### Incorporamos los elementos del gráfico
plot(PREDICHOS, RESIDUOS, main="Predichos vs Residuos entre el sigma0 (VH) y la biomasa de los pastizales para 'Sitio 1'",
      cex.main = 0.9, font.main= 2, cex.lab = 0.8, font.lab = 2, cex.axis = 0.9,
      xlim=c(500, 2000), ylim=c(-620, 620), las=1, pch=19, col="blue",
      panel.first=grid(VI,NULL, lty = 1, col = "lightgray"), abline(a=0, b=0, col="red"))
minor.tick(nx=4, ny=4, tick.ratio=0.3, x.args = list(), y.args = list())

### Gráfico y detección para 'PREDICHOS' vs 'Distancia de COOK'
plot(PREDICHOS, COOK)
### Gráfico y detección para 'PREDICHOS' vs 'RESIDUOS_ESTUDENTIZADOS'
plot(PREDICHOS, RESIDUOS_ESTUDENTIZADOS)
### Aclaración: se utilizó la misma plantilla para la generación de todos los gráficos (PREDICHOS, RESIDUOS_ESTUDENTIZADOS, COOK)

#####
# 2) #Carga de datos SAR y ópticos para el cálculo de Regresión Lineal Múltiple
MI_ARCHIVO <- c("MLRSitio1.csv") #MLRSitio1 #MLRSitio2 (Entre Ríos) #MLRBolzano (Val Mazia)
BASE1 <- read.csv(file = MI_ARCHIVO, sep = ";", dec = ".", header = T)

# 3) Aislamiento de las variables a utilizar.
### Identificamos el número de columna de la variable respuesta y de las variables independientes
NUM_COL_VI1 <- 1 #Polarización VH
NUM_COL_VI2 <- 2 #Ratio VH/VV (sólo para los sitios de estudio en Entre Ríos) #Polarización VV (para el sitio de estudio en Bolzano)
NUM_COL_VI3 <- 3 #índice NDVI
NUM_COL_VI4 <- 4 #Altura media de los pastizales (sólo para los sitios de estudio en Entre Ríos)
NUM_COL_VR1 <- 5 #Biomasa de los pastizales

### Creamos un vector con los objetos seleccionados.
### El nuevo vector contiene el Número de las Columnas Seleccionadas que ingresarán en el análisis de Regresión Lineal Múltiple.
NUM_COL_SEL <- c(NUM_COL_VR1, NUM_COL_VI1, NUM_COL_VI2, NUM_COL_VI3, NUM_COL_VI4)
### Creamos una MINIBASE de datos (MINIBASE1 será un objeto que contiene solo las variables (columnas) que ingresan al análisis).
MINIBASE1 <- BASE1[, NUM_COL_SEL]
### Limpiamos la MINIBASE1 de aquellos datos faltantes (celdas vacías).
### Nos quedan todas las filas que tienen datos completos para el análisis.
MINIBASE1 <- na.omit(MINIBASE1)
### Creamos los objetos... 'VR1', 'VI1', 'VI2', 'VI3' y 'VI4'.
VR1 <- MINIBASE1[,1]
VI1 <- MINIBASE1[,2]
VI2 <- MINIBASE1[,3]
VI3 <- MINIBASE1[,4]
VI4 <- MINIBASE1[,5]

### Verificamos la validez de argumentos para funciones numéricas.
is.numeric(VR1)
is.numeric(VI1)
is.numeric(VI2)
is.numeric(VI3)
is.numeric(VI4)

# 4) Generación de resultados y gráficos
### Crearemos un objeto llamado 'LM' que contendrá todos los cálculos realizados por R para un Modelo Lineal General.
LM <- lm(VR1 ~ VI1 + VI2 + VI3 + VI4)
REGRESION <- summary(LM)
### Ya tenemos realizado el análisis de Regresión Lineal Múltiple, si bien ya tenemos la 'REGRESION' con los valores p.,
### toda interpretación que hagamos solo es válida si los errores son estadísticamente NORMALES y HOMOGENEOS.
### Creamos un nuevo objeto llamado 'RESIDUOS'
RESIDUOS <- LM$residuals
### Estos 'RESIDUOS' ingresarán al test de Shapiro-Wilks y al Gráfico para observar la Homogeneidad de Varianzas de los errores.
### NORMALIDAD DE LOS ERRORES (Test de Shapiro-Wilks)
SHAPIRO <- shapiro.test(RESIDUOS)

### HOMOGENEIDAD DE VARIANZAS DE LOS ERRORES
### Ya tenemos los 'RESIDUOS'. Ahora aislamos los predichos, los residuos estudentizados y los valores Leverage de cada dato.
PREDICHOS <- LM$fitted.values
RESIDUOS_ESTUDENTIZADOS <- rstudent(LM)
COOK <- cooks.distance(LM)
### Gráfico y detección para 'PREDICHOS' vs 'RESIDUOS'
plot(PREDICHOS, RESIDUOS)
### Gráfico y detección para 'PREDICHOS' vs 'Distancia de COOK'
plot(PREDICHOS, COOK)
### Gráfico y detección para 'PREDICHOS' vs 'RESIDUOS_ESTUDENTIZADOS'
plot(PREDICHOS, RESIDUOS_ESTUDENTIZADOS)
### Aclaración: se utilizó la misma plantilla generada anteriormente en el cálculo de Regresión Lineal Simple,
### para incorporarla en todos los gráficos de la Regresión Lineal Múltiple (PREDICHOS, RESIDUOS_ESTUDENTIZADOS, COOK)

### Matriz de correlaciones (todas las variables del modelo de Regresión Lineal Múltiple)
cor(MINIBASE1, method="spearman")
### Gráfico de dispersión (todas las variables del modelo de Regresión Lineal Múltiple)
pairs(MINIBASE1, main="Diagrama de dispersión múltiple para cada par de variables del MLR",
      cex.main = 0.85, font.main = 2, cex.axis = 0.7, font.labels = 2, cex = 0.8, pch = 19, col="darkblue")
```

Anexo E

Supuestos de normalidad e independendencia de cada variable usada en el modelo de regresión lineal simple y múltiple

Verificación de la normalidad de los datos. Test de Shapiro-Wilks:

Hipótesis

H0: Los residuos siguen la distribución normal


H1: Los residuos no siguen la distribución normal

Tabla E.1: Estadísticos de salida del Test de Shapiro-Wilks realizado con todas las variables utilizadas en los modelos SLR y MLR a partir del software R

Shapiro-Wilk normality test data												
Sitio de estudio	Sitio 1 (Entre Ríos, Argentina)				Sitio 2 (Entre Ríos, Argentina)				Bolzano (Italia)			
Variable	σ^0 VH (S-1)	σ^0 VH/VV (S-1)	Índice NDVI (S-2 y L-8)	MLR	σ^0 VH (S-1)	σ^0 VH/VV (S-1)	Índice NDVI (S-2 y L-8)	MLR	σ^0 VH (S-1)	σ^0 VV (S-1)	Índice NDVI (S-2 y L-8)	MLR
Estadístico W	0.923	0.909	0.868	0.977	0.935	0.928	0.906	0.962	0.958	0.965	0.944	0.93593
p-valor	0.348	0.241	0.073	0.953	0.472	0.396	0.222	0.809	0.735	0.835	0.603	0.5087

Como se observa en la tabla el p-valor es mayor que el nivel de significancia (0.05), la hipótesis nula no es rechazada. Se asume una distribución del tipo normal para todas las variables usadas.

Análisis de homogeneidad de varianza de los errores para todas las variables usadas en los modelos SLR y MLR a partir del software R.



E SUPUESTOS DE NORMALIDAD E INDEPENDENCIA DE CADA VARIABLE USADA EN EL MODELO DE REGRESIÓN LINEAL SIMPLE Y MÚLTIPLE

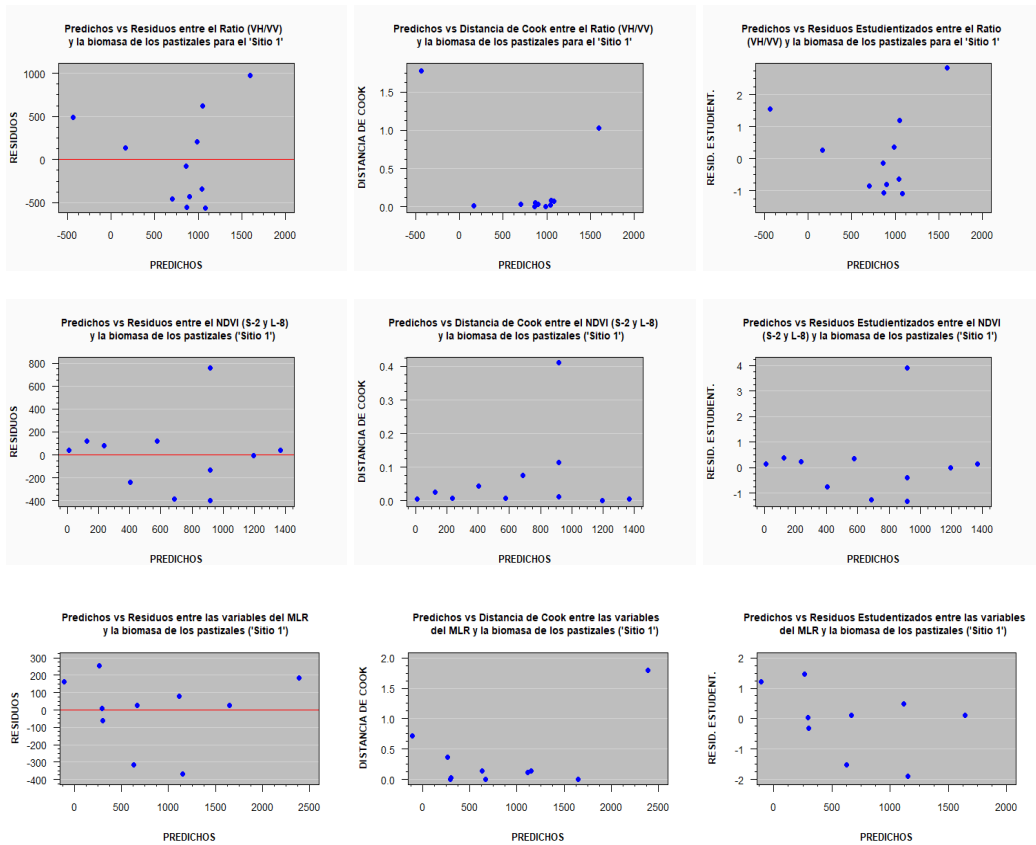
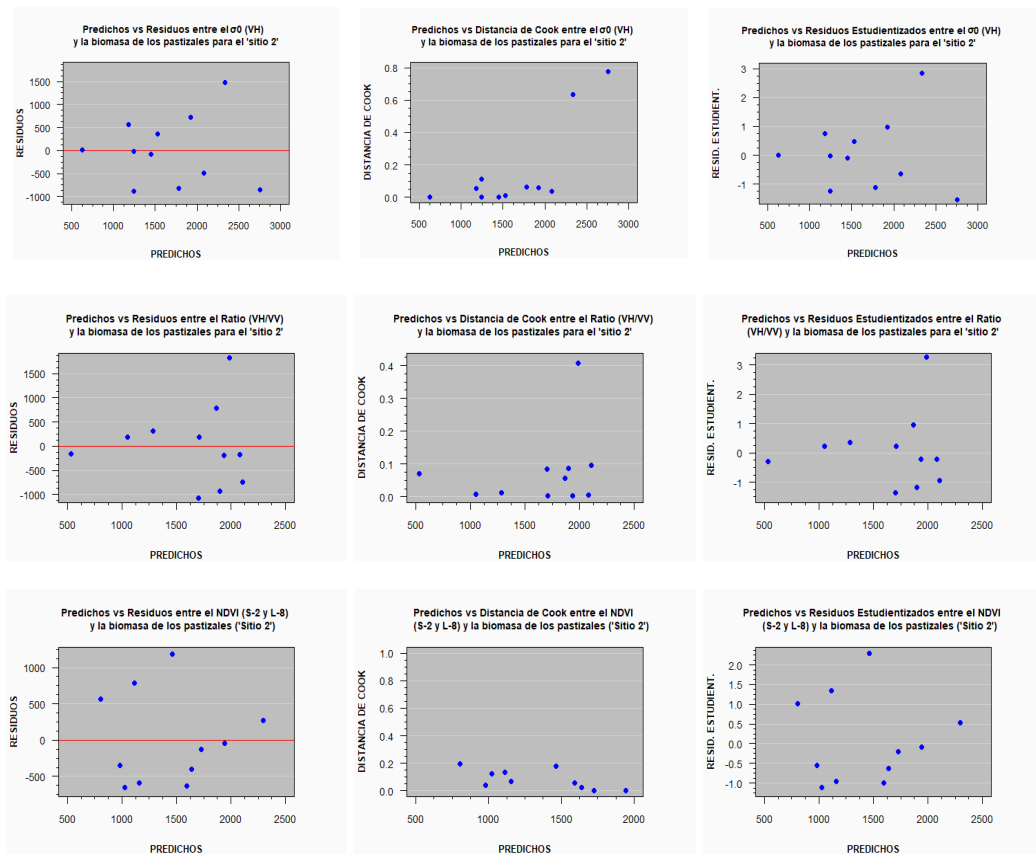


Figura E.1: Homogeneidad de varianza de los errores 'Sitio 1', (Entre Ríos, Argentina)



E SUPUESTOS DE NORMALIDAD E INDEPENDENCIA DE CADA VARIABLE USADA EN EL MODELO DE REGRESIÓN LINEAL SIMPLE Y MÚLTIPLE




Figura E.2: Homogeneidad de varianza de los errores 'Sitio 2', (Entre Ríos, Argentina)

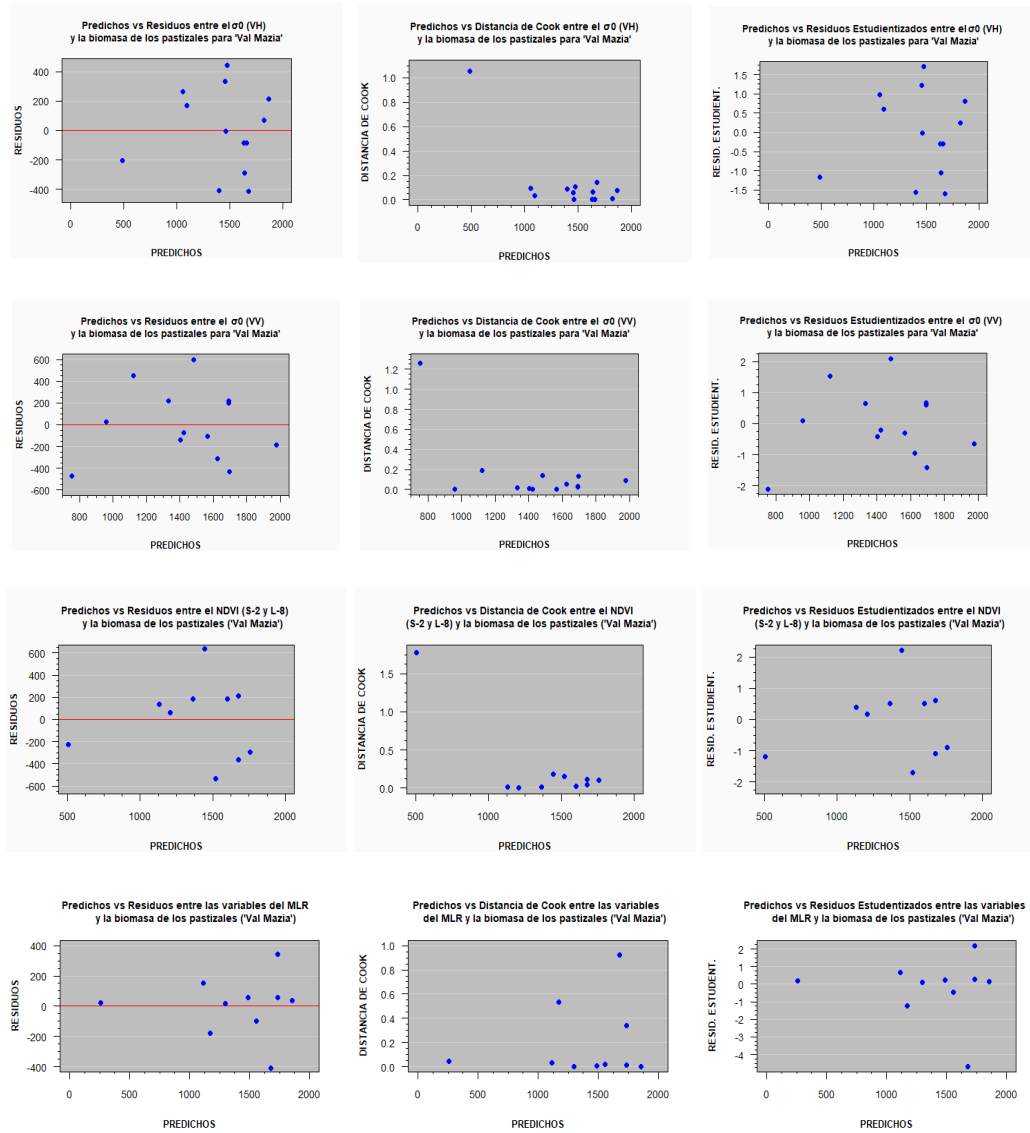


Figura E.3: Homogeneidad de varianza de los errores (Val Mazia, Italia)

Anexo F

Gráficos de la correlación entre el índice NDVI y los índices SAVI y GNDVI (área de estudio: Entre Ríos)

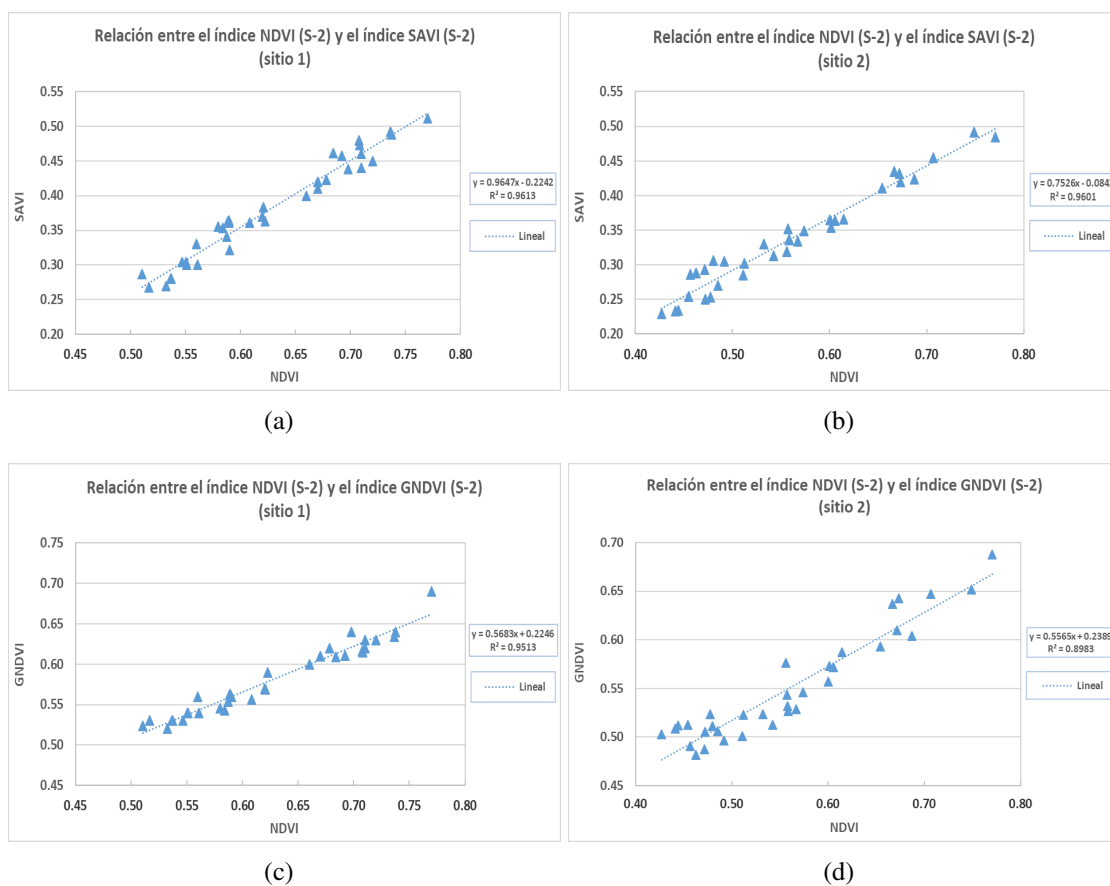




Figura F.1: Relación entre los valores del índice NDVI con respecto a los valores correspondientes de los índices SAVI y GNDVI obtenidos de las imágenes S-2 ('sitio 1' y 'sitio 2')

Anexo G

Gráficos de distribución de todos los valores de (σ_0) y MIBIOP obtenidos en los sitios de estudio de Entre Ríos




(a)




(b)

G GRÁFICOS DE DISTRIBUCIÓN DE TODOS LOS VALORES DE (σ_0) Y MIBIOP OBTENIDOS EN LOS SITIOS DE ESTUDIO DE ENTRE RÍOS



(c)




(d)


Figura G.1: Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en la polarización VH (a) y VV (b) para el 'sitio 1' y en la polarización VH (c) y VV (d) para el 'sitio 2' (Entre Ríos)

Anexo H

Gráficos de distribución de todos los valores de (σ^0) y MIBIOP obtenidos en el sitio de estudio de Val Mazia



(a)




(b)

Figura H.1: Evolución temporal de la biomasa de los pastizales y valores de retrodispersión en la polarización VH (a) y VV (b), Val Mazia


Anexo I

Correlación entre los sensores ópticos S-2 y L-8



(a)

Figura I.1: Correlación entre los valores de NDVI obtenidos a partir de los sensores S-2 y L-8 en el área de estudio 'sitio 1'



(a)

Figura I.2: Correlación entre los valores de NDVI obtenidos a partir de los sensores S-2 y L-8 en el área de estudio 'sitio 2'

Anexo J

Imágenes utilizadas en la identificación y mapeo de áreas con pastizales en la región centro-norte de Entre Ríos

Tabla J.1: Imágenes S-2 utilizadas para la clasificación (región centro-norte de Entre Ríos, Argentina)

S2A_MSIL1A_20170404T135111_N0204_R024_T21JUG_20170404T135511
S2A_MSIL1A_20170713T135111_N0205_R024_T21JUG_20170713T135510
S2B_MSIL1A_20170728T135109_N0205_R024_T21JUG_20170728T135842
S2B_MSIL1A_20170817T135109_N0205_R024_T21JUG_20170817T135131
S2A_MSIL1A_20170911T135111_N0205_R024_T21JUG_20170911T135331

Tabla J.2: Imágenes S-1 utilizadas para la clasificación (región centro-norte de Entre Ríos, Argentina)

S1B_IW_GRDH_1SDV_20170415T091256_20170415T091321_005169_0090BE_6CEF_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170509T091257_20170509T091322_005519_009AB7_DC15_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170614T091259_20170614T091324_006044_00A9CE_80EB_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170626T091300_20170626T091325_006219_00AEE4_AFB8_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170720T091301_20170720T091326_006569_00B8D7_1CBB_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170801T091302_20170801T091327_006744_00BDDE_2D35_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170825T091303_20170825T091328_007094_00C807_D71C_Orb_Cal_Spk_NR_TC_dB.data
S1B_IW_GRDH_1SDV_20170906T091303_20170906T091328_007269_00CD1D_EEE8_Orb_Cal_Spk_NR_TC_dB.data

Anexo K

Matrices de confusión

Tabla K.1: Matrices de confusión calculadas para cada modelo de clasificación evaluado en la región centro-norte de Entre Ríos

Clasificación con Mahalanobis (S-2)

Presición global (7229/8104) 89.2 %

Coefficiente Kappa = 0.85

Datos de referencia a terreno (Porcentaje)						
Clases	Arroz (validación)	Monte Nativo (validación)	Otras Coberturas (validación)	Pastizales (validación)	Total	Precisión Usuario (%)
Arroz	99.53	0	0	2.78	39.4	99
Monte Nativo	0	90.03	12.02	0.7	11.88	60.02
Otras Coberturas	0	0	75.89	0	29.37	100
Pastizales	0.47	9.97	12.09	96.52	19.35	70.79
Total	100	100	100	100	100	
Prec. Productor (%)	99.53	90.03	75.89	96.52		

Clasificación con K-Means (S-2)

Presición global (7201/7781) = 92.55%

Coefficiente Kappa = 0.89

Datos de referencia a terreno (Porcentaje)						
Clases	Arroz (validación)	Monte Nativo (validación)	Otras Coberturas (validación)	Pastizales (validación)	Total	Precisión Usuario (%)
Arroz	100	0	0	0	40.73	100
Monte Nativo	0	98.6	13.27	18.59	15.47	98.6
Otras Coberturas	0	0	86.73	0	34.96	86.73
Pastizales	0	1.4	0	81.41	8.84	81.41
Total	100	100	100	100	100	
Prec. Productor (%)	100	98.6	86.73	81.41		

Clasificación con Mahalanobis (S-1)

Presición global (7513/8104) 92.8 %

Coefficiente Kappa = 0.89

Datos de referencia a terreno (Porcentaje)						
Clases	Arroz (validación)	Monte Nativo (validación)	Otras Coberturas (validación)	Pastizales (validación)	Total	Precisión Usuario (%)
Arroz	99.09	0	1.88	0	39.56	98.16
Monte Nativo	0	100	0.29	0	8.03	98.62
Otras Coberturas	0.66	0	82.27	0.52	32.17	98.96
Pastizales	0.25	0	15.56	99.48	20.24	69.76
Total	100	100	100	100	100	
Prec. Productor (%)	99.09	100	82.27	99.48		

Clasificación con K-Means (S-1)

Presición global (6827/8026) 85.06 %


Coefficiente Kappa = 0.79

Datos de referencia a terreno (Porcentaje)						
Clases	Arroz (validación)	Monte Nativo (validación)	Otras Coberturas (validación)	Pastizales (validación)	Total	Precisión Usuario (%)
Arroz	100	0	0.86	0	38.94	99.14
Monte Nativo	0	100	0	0	8	100
Otras Coberturas	0	0	62.4	1.74	24.63	98.99
Pastizales	0	1.4	36.73	98.26	28.43	49.52
Total	100	100	100	100	100	
Prec. Productor (%)	100	100	62.4	98.26		

Anexo L

Puntos aleatorios obtenidos sobre el área de interés (Centro-norte Entre Ríos) para análisis post-clasificación

Tabla L.1: Puntos aleatorios de validación obtenidos con QGIS sobre la región centro-norte de Entre Ríos



Anexo M

Mapa de clasificación comparativo

Tabla M.1: Mapa de clasificación obtenida por la plataforma Copernicus Global Land Service para la región centro-norte de Entre Ríos

