

Caracterización de rotaciones de cultivos y su impacto en el rendimiento y funcionamiento de sistemas agrícolas

*Tesis presentada para optar al título de Doctor de la Universidad de Buenos Aires,
Área Ciencias Agropecuarias*

Diego de Abelleira

Ingeniero Agrónomo - Universidad de Buenos Aires - 1999

Magister - Universidad de Buenos Aires - 2008

Lugar de trabajo: Instituto de Clima y Agua, INTA



FAUBA Escuela para Graduados Ing. Agr. Alberto Soriano
Facultad de Agronomía – Universidad de Buenos Aires



COMITÉ CONSEJERO

Director de tesis

Santiago R. Verón

Ingeniero Agrónomo (Universidad de Buenos Aires)

Doctor en Ciencias Agropecuarias (Universidad de Buenos Aires)

Co-director

Lucas Borrás

Ingeniero Agrónomo (Universidad de Buenos Aires)

Doctor en Ciencias Agropecuarias (Universidad de Buenos Aires)

JURADO DE TESIS

JURADO

Nombre/s y apellido/s

Título de grado (Universidad)

Título de posgrado (Universidad)

JURADO

Nombre/s y apellido/s

Título de grado (Universidad)

Título de posgrado (Universidad)

JURADO

Nombre/s y apellido/s

Título de grado (Universidad)

Título de posgrado (Universidad)

Fecha de defensa de la tesis: 27 de abril de 2023

Dedicatoria

A mi familia, Nati, Lucas y Julieta.

Agradecimientos

Al INTA, por el soporte en la toma de muestras y relevamientos a campo.

Al grupo de trabajo de INTA (Santiago's, Tamara, Antonella, Cielo, Ignacio y Alejandro), por la colaboración en los relevamientos y consultas específicas.

A Fernando Mousegne, Santiago Levantini y productores del partido de San Antonio de Areco (Estancia La Fé, Santa Escolástica, Río Areco y San Ramón) por la predisposición a la realización de mediciones a campo y la atención de consultas.

A mis directores por el tiempo dedicado.

Declaración

Declaro que el material incluido en esta tesis es, a mi mejor saber y entender, original producto de mi propio trabajo (salvo en la medida en que se identifique explícitamente las contribuciones de otros), y que este material no lo he presentado, en forma parcial o total, como una tesis en ésta u otra institución.



Diego de Abelleira

Publicaciones derivadas de la tesis

de Abelleira, D., Verón, S. 2020. Crop rotations in the Rolling Pampas:

Characterization, spatial pattern and its potential controls. *Remote Sensing Applications:*

Society and Environment, 18:100320.

Índice general

Dedicatoria.....	iii
Agradecimientos.....	iv
Declaración.....	v
Publicaciones derivadas de la tesis.....	vi
Índice general.....	vii
Índice de cuadros.....	xi
Índice de figuras.....	xiv
Abreviaturas.....	xx
Resumen.....	xxii
Abstract.....	xxiv
CAPÍTULO I	
Introducción General.....	1
1.1. Introducción.....	2
1.2. Objetivos e hipótesis de trabajo.....	11
1.3. Estructura de la tesis.....	13
CAPÍTULO II	
Rotaciones en la Pampa Ondulada: Caracterización, patrones espaciales y posibles controles.....	14
2.1. Introducción.....	15
2.2 Materiales y Métodos.....	18
2.2.1. Área de estudio.....	18
2.2.2. Clasificación de cultivos y generación de mapas de secuencias de cultivos.....	20
2.2.2.1 Metodología de clasificación.....	21

2.2.3. Análisis de datos.....	23
2.3. Resultados.....	26
2.3.1 Clasificación de cultivos.....	26
2.3.2. Análisis de secuencias de cultivos.....	28
2.4. Discusión.....	36
2.5. Conclusiones.....	40
CAPÍTULO III	
Caracterización del crecimiento de soja a partir de RADAR de Apertura Sintética (SAR) y sensores ópticos.....	
	42
3.1. Introducción.....	43
3.2. Materiales y Métodos.....	47
3.2.1. Área de estudio.....	47
3.2.2. Imágenes satelitales.....	47
3.2.3. Mediciones a campo.....	49
3.2.4. Análisis de datos y modelado.....	51
3.3. Resultados.....	53
3.3.1. Análisis considerando el ciclo de crecimiento completo.....	53
3.3.2. Análisis considerando diferentes períodos a lo largo del ciclo de crecimiento.....	55
3.3.3. Desarrollo de un modelo integrando información derivada de información SAR y óptica para estimar biomasa seca en cultivos de soja ...	57
3.3.4. Validación.....	60
3.4. Discusión.....	61
3.5. Conclusiones.....	65

CAPÍTULO IV

Estimación del impacto de rotaciones en la Pampa Ondulada en el crecimiento de cultivos y el carbono del suelo.....	67
4.1. Introducción.....	68
4.2. Materiales y Métodos.....	71
4.2.1. Variables explicativas.....	71
4.2.2. Variables de respuesta.....	72
4.2.2.1. Implementación del modelo de biomasa.....	74
4.2.3. Análisis del impacto de rotaciones.....	76
4.3. Resultados.....	80
4.3.1. Impacto de las secuencias de cultivos en el crecimiento de soja.....	80
4.3.2. Impacto de las secuencias de cultivo en el carbono del suelo.....	81
4.4. Discusión.....	82
4.5. Conclusiones.....	86

CAPÍTULO V

Análisis de secuencias de cultivos a escala nacional.....	88
5.1. Introducción.....	89
5.2. Materiales y Métodos.....	92
5.3. Resultados.....	96
5.4. Discusión.....	103
5.5. Conclusiones.....	106

CAPÍTULO VI

Conclusiones Generales.....	108
6.1. Aspectos generales.....	109
6.1.1. Principales logros de la tesis.....	109

6.1.2. Contratación de hipótesis planteadas.....	113
6.1.3. Implicancias para el manejo sostenible de los recursos naturales.....	116
6.2. Avances logrados en el conocimiento.....	117
6.3. Líneas emergentes de investigación.....	119
REFERENCIAS.....	121
7. Referencias.....	122
APÉNDICE.....	145
8.1 Cuadros y Figuras Apéndices. Capítulo III.....	146
8.2 Cuadros y Figuras Apéndices. Capítulo IV.....	155
8.3. Cuadros y Figuras Apéndices. Capítulo V.....	162

Índice de cuadros

CAPITULO 2

Cuadro 2.1. Número de escenas de las diferentes plataformas satelitales utilizadas en el área de estudio durante las siete campañas agrícolas consideradas (2010-2017).....19

Cuadro 2.2. Número de polígonos (lotes) registrados para cada clase durante las siete campañas agrícolas consideradas. Clases: M1, maíz temprano; M2, maíz tardío, S1, soja de primera; TS, doble cultivo trigo-soja, FORR, no agrícola....21

Cuadro 2.3. Exactitudes de clasificación obtenidas durante cada campaña agrícola. Clases: M1, maíz temprano; M2: maíz tardío; S1; soja de primera; TS, doble cultivo trigo-soja; FORR, no agrícola.....27

Cuadro 2.4. Coeficientes de Regresión Logística para explicar la ocupación de sitios con cinco o más años de monocultivo de soja y con cinco o más años de rotación recomendada.....36

CAPITULO 3

Cuadro 3.1. Coeficientes de determinación de los modelos ajustados para las variables medidas en cultivos de soja y suelo a lo largo de todo el período de medición. Se identifica el mejor modelo (lin: lineal, o log: logarítmico) según el criterio de Akaike.....54

Cuadro 3.2. Coeficientes de determinación de los modelos ajustados para las variables biomasa seca y fresca en dos sub-períodos: previo y posterior al

momento de máximo IVN. Se identifica el mejor modelo (lin: lineal, o log: logarítmico) según el criterio de Akaike.....57

CAPITULO 4

Cuadro 4.1. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas. Los parámetros se presentan estandarizados (coeficiente Beta).....81

Cuadro 4.2. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas. Los parámetros se presentan estandarizados (coeficiente Beta).....81

Cuadro 4.3. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico en los primeros 20 cm del suelo. Los parámetros se presentan estandarizados (coeficiente Beta).....82

CAPITULO 5

Cuadro 5.1. Clases de los mapas unificados por campaña a partir de los Mapas Nacionales de Cultivos de las campañas 2018/2019, invierno 2019, verano 2020, invierno 2020 y verano 2021.....93

Cuadro 5.2. Coeficientes de regresión lineal simple entre distancia a puertos y área cubierta con distintas proporción de siembra de soja de primera sembrada durante las tres campañas analizadas.....99

Cuadro 5.3. Coeficientes de regresión lineal simple entre precipitación media anual y área cubierta por cada una de las intensidades de siembra consideradas.....101

Cuadro 5.4. Coeficientes de regresión lineal simple entre precipitación media anual y área cubierta según el número de especies identificado durante las tres campañas analizadas.....102

Índice de figuras

CAPITULO 2

- Figura 2.1. Área de estudio delimitada por la intersección de las escenas satelitales adquiridas durante el período considerado (2010-2017). Izquierda: Subregiones de la región Pampeana Argentina (Oyarzabal et al. 2018). Derecha: Imagen del satélite Sentinel 2- Agencia Espacial Europea (06/09/2016).....19
- Figura 2.2. Mapas de cultivos para las siete campañas agrícolas consideradas. Las zonas enmascaradas incluyen ríos, cuerpos de agua y zonas urbanas.....29
- Figura 2.3. A) Área de las clases de cultivos clasificadas, expresada como proporción del área agrícola (sin considerar áreas no agrícolas) para las siete campañas agrícolas consideradas; B) Precio de exportación de cultivos (promedio anual) de maíz, soja y trigo durante el período de estudio. Fuente: FAOSTAT (2018).....30
- Figura 2.4. Número de años consecutivos con las secuencias de cultivo analizadas: A) monocultivo de soja; B) rotación recomendada (maíz / soja de primera / trigo-soja); C) rotación de cultivos de verano (maíz / soja de primera).....32
- Figura 2.5. Área identificada con diferentes secuencias de cultivos durante un número creciente de años consecutivos expresada como proporción del área agrícola (sin considerar áreas no agrícolas). Línea negra, monocultivo de soja; línea roja, rotación recomendada, línea naranja, probabilidad de ocurrencia

aleatoria de monocultivo considerando tres posibles casos de ocupación: maíz, soja de primera y trigo-soja.....33

Figura 2.6. Área de transición de cultivos a lo largo de diferentes sub-períodos de dos años (expresados como el porcentaje del área del cultivo en la segunda campaña con respecto al cultivo en la primera campaña). Soja de primera después de maíz (verde); soja de primera después de soja de primera (negro); trigo-soja después de soja de primera (rojo); maíz después de trigo-soja (azul). El eje de las x muestra la última campaña de cada sub-período.....34

Figura 2.7. Función de Correlación de Pares (PCF) para los casos de cinco o más años de monocultivo de soja (línea negra) y de rotación recomendada (línea roja). Línea azul representa el valor esperado de una distribución espacial aleatoria.....35

CAPITULO 3

Figura 3.1. Fecha de mediciones realizadas a campo y de adquisiciones de imágenes de las plataformas RADARSAT 2, TerraSAR-X, Landsat y MODIS. El eje secundario muestra los valores de precipitación a lo largo de la campaña 2011/2012 (barras azules).....49

Figura 3.2. Ejemplo de la configuración espacial de las mediciones a campo. Puntos rojos: sitios de muestreo; polígonos blancos: contorno de píxel de la plataforma MODIS en proyección sinusoidal; polígonos amarillos: borde de lote de cultivo.....51

Figura 3.3. Relación entre coeficiente de retrodispersión en RADARSAT 2 HV y a) biomasa seca (modelo ajustado: $y=22,353+\log(1,324x)$, r^2 aj.=0,72) y b) biomasa fresca (modelo ajustado: $y=-26,584+\log(1,578x)$, r^2 aj.=0,83).....56

Figura 3.4. Diagramas de caja de mediciones de contenido de humedad de la vegetación a lo largo del ciclo de crecimiento en cultivos de soja durante la campaña 2011/2012.....59

Figura 3.5. Contenido de humedad de la vegetación vs. IVN de MODIS, antes (puntos azules) y después (puntos rojos) del máximo de IVN. Las líneas representan los modelos ajustados para ambos sub-períodos: previo al máximo de IVN (azul; $y=81.5-1.92x$; r^2 aj.=0.04) y después del máximo de IVN (rojo; $y=-64.39+313.1x-176.1x^2$; r^2 aj.=0.85).....59

Figura 3.6. Comparación entre valores medidos y estimados de: a) biomasa seca estimada a partir de RADARSAT 2 polarización HV ($y=1219,25+0,5932x$); b) biomasa seca estimada a partir de RADARSAT 2 y Landsat ($y=953,53174+0,53935x$); y c) biomasa fresca estimada con RADARSAT 2 polarización HV ($y=2271,3987+0,757x$). La raíz del cuadrado medio del error (RMSE) está en kg ha^{-1}61

CAPITULO 4

Figura 4.1. Variables de entrada para el análisis del impacto de las rotaciones: a) Número de períodos (de 2 años consecutivos) con soja de primera; b) Número de períodos (de 2 años consecutivos) con rotación recomendada (maíz / soja de primera / trigo-soja); c) Proporción de gramíneas en la rotación; d) proporción

de soja de primera en la rotación; e) Intensidad de siembra (número de cultivos por año).....73

Figura 4.2. Secuencia temporal de escenas RADARSAT 2 en polarización HV adquiridas en el sitio de estudio durante la campaña 2018/2019.....74

Figura 4.3. Áreas de estudio: polígono rojo: límite para la estimación de índices de rotación (a partir de mapas de secuencias de cultivos - sección 2.3.1); polígono azul: área cubierta por las escenas RADARSAT 2 obtenidas durante la campaña 2018/2019 que permiten estimar biomasa seca; puntos verdes: sitios con mediciones de carbono del suelo del Observatorio Nacional de Suelos Agropecuarios (ONSA 2023) realizadas entre marzo y abril de 2019.....75

Figura 4.4. Esquema de implementación del modelo de biomasa seca a partir de información de RADAR y óptica (sección 3.3.3).....77

Figura 4.5. Evolución temporal de la biomasa fresca de cultivos de soja utilizando imágenes RADARSAT 2 a lo largo de la campaña 2018/2019.....77

Figura 4.6. Evolución temporal de la biomasa seca de cultivos de soja utilizando el modelo que integra información de RADAR y óptica a lo largo de la campaña 2018/2019.....78

Figura 4.7. Diagramas de caja del peso fresco y seco estimado para cultivos de soja de primera y de segunda a lo largo de la campaña agrícola 2018/2019.....78

CAPITULO 5

- Figura 5.1. Esquema de cambio en la disponibilidad de información a partir de mapas en alta resolución (que permiten identificar lotes) frente a la disponibilidad de información a nivel de departamento.....91
- Figura 5.2. Mapas unificados por campaña (incluyendo cultivos de invierno y verano) a partir del Mapa Nacional de Cultivos para las campañas 2018/2019, 2019/2020 y 2020/2021.....95
- Figura 5.3.a) Distancia a puertos (a partir de información de ubicación de puertos provista por el Instituto Geográfico Nacional de Argentina); b) Precipitaciones totales (promedio por campaña) durante las tres campañas analizadas (2018/2019, 2019/2020 y 2020/2021) a partir de la base de datos CHIRPS. Se mapearon solamente las áreas agrícolas.....96
- Figura 5.4.a) Número de especies sembradas a lo largo de las tres campañas agrícolas consideradas (2018/2019, 2019/2020 y 2020/2021). b) Intensidad de siembra (promedio del número de cultivos por campaña).....98
- Figura 5.5. Número de secuencias (sub-períodos de dos años) que mostraron rotación (cambio en el cultivo identificado - a) y proporción de la clase soja de primera (cultivo único - b) durante las tres campañas agrícolas consideradas (2018/2019, 2019/2020 y 2020/2021).....99
- Figura 5.6.a) Casos con diferente proporción de soja de primera durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) en Zona Núcleo (zonas VI y VII del Mapa Nacional de Cultivos (de Abelleira et al.

2019)). Área de casos con diferente proporción de soja de primera durante las tres campañas agrícolas analizadas a lo largo de un gradiente de distancia a puertos: b) Zona VI: Núcleo Norte, c) zona VII: Núcleo Sur.....100

Figura 5.7. Área de casos con diferente intensidad de siembra (número de cultivos por año) durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) a lo largo de un gradiente de precipitación media anual sobre las principales regiones agrícolas de Argentina.....102

Figura 5.8. Área de casos con diferente número de especies durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) a lo largo de un gradiente de precipitación media anual sobre las principales regiones agrícolas de Argentina.....103

Abreviaturas

<i>ABREVIATURA</i>	<i>SIGNIFICADO</i>
σ^0	Coefficiente de retrodispersión
<i>AACREA</i>	Asociación Argentina de Consorcios Regionales de Experimentación Agrícola
<i>dB</i>	decibeles
<i>DB</i>	Biomasa seca
<i>FAOSTAT</i>	Datos estadísticos corporativos de la Organización para la Agricultura y la Alimentación
<i>HH</i>	Sistema de polarización con emisión horizontal y recepción horizontal
<i>HV</i>	Sistema de polarización con emisión horizontal y recepción vertical
<i>IR</i>	Infrarrojo
<i>INTA</i>	Instituto Nacional de Tecnología Agropecuaria
<i>IVN</i>	Índice de Vegetación Normalizado
<i>JECAM</i>	Experimentos Conjuntos para la Identificación y Seguimiento de Cultivos
<i>MINAGRI</i>	Ministerio de Agricultura, Ganadería y Pesca, Argentina
<i>ONSA</i>	Observatorio Nacional de Suelos Agropecuarios
<i>PCF</i>	Función de correlación de pares
<i>RADAR</i>	Detección y Distanciamiento de RADIO (derivado del acrónimo inglés de <i>Radio Detection and Ranging</i>)

ABREVIATURA SIGNIFICADO

<i>RS-2</i>	RADARSAT 2
<i>FAPAR</i>	Fracción de radiación fotosintéticamente activa interceptada
r^2	Coefficiente de determinación
<i>RMSE</i>	Cuadrado medio del error
<i>SAR</i>	RADAR de Apertura Sintética (derivado del acrónimo inglés de <i>Synthetic Aperture</i> RADAR).
<i>SMAPVEX 12</i>	Experimento de Validación de la Misión <i>Soil Moisture Active Passive</i>
<i>SRTM</i>	Misión Topográfica del Transbordador Espacial (derivado del acrónimo inglés de <i>Shuttle Radar Topography Mission</i>)
<i>TSX</i>	TerraSAR-X
<i>URL</i>	localizador de recursos uniforme (derivado del acrónimo inglés de <i>Uniform Resource Locator</i>)
<i>VH</i>	Sistema de polarización con emisión vertical y recepción horizontal
<i>VM</i>	Contenido de humedad de la vegetación
<i>VV</i>	Sistema de polarización con emisión vertical y recepción vertical
<i>WB</i>	Biomasa fresca

Caracterización de rotaciones de cultivos y su impacto en el rendimiento y funcionamiento de sistemas agrícolas

Resumen

El análisis de las rotaciones de cultivos a escala regional requiere información histórica a nivel de lote que considere las diferentes condiciones presentes en el área. Esta información ha sido de escasa y dispersa en Argentina durante los últimos años, a pesar de existir herramientas que permitían obtenerla. Es posible a partir de sensores remotos la identificación de los cultivos sembrados en un área y la estimación del crecimiento y rendimiento. El objetivo de esta tesis fue la caracterización de las secuencias de cultivos a lo largo de una serie de campañas agrícolas y la evaluación de su impacto a nivel productivo y ambiental. Se generaron mapas de cultivos a lo largo de siete campañas agrícolas en un área piloto de la Pampa Ondulada donde se analizó la ocurrencia de casos de monocultivo y rotación en relación a variables humanas y ambientales. Se desarrolló un modelo de estimación de biomasa en soja como indicador del estado y rendimiento del cultivo. Se evaluó el efecto de diferentes secuencias de cultivos en la producción de biomasa de lotes de soja y en el carbono orgánico del suelo. A nivel nacional se analizaron las secuencias de cultivos a lo largo de tres campañas. Los casos de monocultivo estuvieron asociados a parcelas catastrales pequeñas comúnmente asignadas a arrendamiento y se agruparon en cercanías a centros de acopio para transporte e industrialización. Se observó un efecto positivo y significativo en biomasa de soja para índices relacionados con el número de períodos con rotación y con la proporción de gramíneas, mientras que se identificaron efectos negativos y significativos con la proporción de soja de primera y con la intensidad de

siembra. El análisis espacial de secuencias de cultivos permite identificar controles de su distribución y proponer estrategias que favorezcan la implementación de buenas prácticas agrícolas.

Palabras clave: monocultivo, soja, RADAR, biomasa, socioecosistemas

Characterization of crop rotations and its impact on yield and on functioning of agricultural systems

Abstract

Crop rotation analysis at regional level requires the availability of information about planting history at field level that considers the different conditions in the area. This kind of information has been scarce and dispersed in Argentina during last years despite the availability of tools to generate it. Through remote sensing it is possible to identify crops planted in an area and the estimation of crop growing and yield. The objective of this thesis was to characterize crop sequences along a serie of growing seasons and to evaluate its impact in productivity and environment. Seven crop type maps were generated along consecutive growing seasons in a pilot site in Pampa Ondulada where the occurrence of monoculture and rotation was analyzed in relation to human and environmental variables. In addition, a model for the estimation of soybean biomass as a proxy of crop condition and yield was developed. The effect of different crop sequences was evaluated in relation to soybean biomass production and soil organic carbon. At national level, crop sequences were analyzed along three growing seasons. The occurrence of monoculture was associated to small cadastral units where tenancy is frequent, and were grouped near transporting and industrial centers. A positive and significant effect on soybean biomass was observed for indices related to the number of rotation periods and the proportion of cereals; while negative and significant effects were found for the number of periods with monoculture, the total number of periods with early soybean and with planting intensity. Spatial analysis of

crop sequences allows to identify controls of its occurrence and to develop tools that promote the implementation of good agricultural practices.

Key words: monoculture, soybean, RADAR, biomass, socioecosystems

Capítulo I

Introducción General

1.1. Introducción

En los últimos tres siglos las actividades humanas han transformado el ambiente de manera significativa, siendo la conversión de ecosistemas naturales a agricultura la principal modificación en extensión de la superficie terrestre (Ramankutty & Foley 1999). La agricultura moderna ha sido muy eficiente en el incremento en la producción de alimentos para satisfacer las necesidades alimentarias globales (Pellegrini et al. 2018), a través de sistemas simplificados, con alta frecuencia de disturbios y gran aplicación de insumos que pueden generar importantes impactos en el ambiente (Tilman 1999). La persistencia de las sociedades humanas como las conocemos actualmente depende del equilibrio entre la satisfacción de sus necesidades humanas y el mantenimiento de un ambiente sano. Este desafío requiere mejorar nuestro conocimiento de los aspectos sociales y ecológicos de los sistemas agrícolas así como también disponer de herramientas que permitan la estimación de su impacto ambiental.

Los sistemas agrícolas pueden ser considerados socioecosistemas donde existen elementos ecológicos y humanos que son controlados por factores endógenos y exógenos que operan a distinta escala espacial y temporal (Chapin et al. 2009). Los controles exógenos por definición se encuentran por fuera de los límites del sistema y representan factores que influyen sobre el sistema, pero éste puede ejercer poca o nula influencia. Ejemplos de controles exógenos son el clima o los sistemas de gobierno y por lo general se mantienen relativamente constantes sobre regiones o continentes y largos periodos de tiempo. Por el contrario, los controles endógenos se encuentran dentro de los límites del sistema y pueden ser modificados por su propia dinámica interna. Los controles endógenos se pueden diferenciar en variables lentas que cambian en términos de años o décadas y variables rápidas que cambian a paso horario, diario o

estacional. Este tipo de variables están interrelacionadas, pudiendo incluso un conjunto de variables rápidas ser parte de una variable o proceso lento (Carpenter et al. 2002).

Entender la dinámica de los socioecosistemas y cuantificar su impacto requiere la consideración de factores humanos y biofísicos a diferentes escalas espaciales y temporales. Por ejemplo, en sistemas agrícolas, el rendimiento obtenido en un lote dependerá de las condiciones meteorológicas experimentadas durante la estación de crecimiento, del tipo de suelo y decisiones de manejo como la elección del cultivo sembrado, del material genético, prácticas de fertilización. A su vez, las decisiones de manejo pueden verse modificadas por variaciones en la humedad del suelo a la siembra, la disponibilidad de capital del productor, la forma de tenencia de la tierra, los pronósticos meteorológicos de mediano plazo, el precio internacional de dicho producto y/o regulaciones comerciales o fiscales.

La rotación agrícola representa el cambio de un cultivo a otro entre siembras sucesivas en un mismo lote, mientras que el monocultivo implica la repetición del mismo cultivo en siembras sucesivas. La historia de cultivos sembrados en un lote (incluyendo períodos de rotación, monocultivo o una combinación de éstas), se denomina secuencia de cultivos, y puede mostrar efectos sobre el rendimiento a diferentes escalas temporales (Dury et al. 2012; Martini y Angeli 2017). Es así que podría haber un efecto de variables de corto plazo, o variables rápidas, derivados del cultivo antecesor (e.g. nivel de acumulación de agua y disponibilidad de nitratos), o de largo plazo (variables lentas) asociados a una secuencia de cultivos de varios años (e.g. cambios en la disponibilidad o distribución del carbono del suelo que afecten sus características físicas). Es decir, al igual que en otros sistemas, en la agricultura existirían procesos que conectan la dinámica actual del sistema a eventos ocurridos en el pasado. Estos mecanismos involucran por lo general transferencias de recursos (e.g.

dinero, agua y/o nutrientes del suelo) o de información (e.g. prácticas de manejo óptimas) entre años. Si bien en los sistemas agrícolas la frecuencia de disturbios (e.g. labranzas) y los subsidios energéticos (e.g. aplicación de agroquímicos, etc.) en general disminuyen la intensidad de los mecanismos de transferencia temporal, aún resta identificar y cuantificar la importancia de estos procesos.

La producción agrícola argentina se ha incrementado en gran medida durante los últimos años, pasando la producción de los principales granos (soja, maíz, trigo y girasol) de 34 a 112 millones de toneladas entre 1990 y 2015 (MINAGRI, 2017). En 2013, Argentina fue el tercer exportador mundial de soja y maíz y el décimo tercero de trigo (FAOSTAT, 2018) representando la agricultura una fuente de divisas y de ingresos fiscales clave para el país. El aumento de la producción ocurrió principalmente a través de dos procesos: i) la expansión de la agricultura hacia nuevas áreas como Chaco y Mesopotamia y ii) la intensificación de la agricultura en la región Pampeana, que incluyó cambios en la proporción de cultivos en una rotación, cambios en el número de cultivos por año y en nivel de insumos utilizados (Paruelo et al. 2005, Viglizzo et al. 2011). La difusión de la siembra directa y la aparición de organismos genéticamente modificados permitieron la adopción de agricultura continua en gran parte del territorio en desmedro de rotaciones agrícola-ganaderas.

A pesar de la importancia del sector agrícola en la economía argentina, el conocimiento acerca de los cambios -y sus consecuencias- ocurridos en las últimas décadas es principalmente cualitativo e incompleto. Numerosas fuentes señalan que la ocurrencia del monocultivo de soja es una práctica dominante en las regiones agrícolas de Argentina (Barros et al. 2015; Duval et al. 2015; Haro Sly 2017). Estas se basan en conocimiento experto, o en estimaciones agrícolas del Ministerio de Agroindustria (MINAGRI, 2017), que muestran un gran aumento en el área sembrada de soja. Esta

última información está disponible a nivel de departamento y hasta hace unos años no diferenciaba entre área de soja de primera (único cultivo de la campaña) y soja de segunda (sembrada luego de un cultivo de invierno). Existe una falta de información para cuantificar de manera objetiva el grado de monocultivo de soja o de rotación de cultivos a escala regional o nacional. Esto requiere disponer de información de la secuencia de cultivos en cada lote en una región de interés. La generación de mapas de cultivos anuales en forma secuencial que detallen lo que ocurre en cada lote, permite obtener mapas de secuencias de cultivos y así cuantificar la ocurrencia de monocultivo o rotación y evaluar su relación con factores biofísicos y humanos en la medida en que haya información disponible en similar escala espacial o temporal.

La decisión del plan de siembra a nivel de establecimiento o lote, depende de numerosos factores (Steinmann y Dobers 2013). Existen restricciones a la siembra de ciertos cultivos en algunos ambientes, por ejemplo el maíz tiene requerimientos de suelos con gran capacidad de retención hídrica (Zeljovich 2015); el trigo presenta restricciones hídricas a su siembra en secano en sectores del oeste de Argentina debido a la frecuencia de stress hídrico durante invierno y primavera (Gastaldi et al. 2020). Es así que un planteo de rotación podría estar limitado en cuanto a especies por las condiciones ambientales del sitio. También influyen en la decisión de siembra factores humanos como el precio internacional de los granos, margen bruto y costos de producción, y el tipo de tenencia de la tierra (Soule et al. 2000; Bert et al. 2011; Videla Mensegue et al. 2022), siendo influyente en este último caso la duración de contratos de arrendamiento. En Uruguay, Arbeletche et al. (2010) señalan un incremento de la superficie sembrada con soja en casos de arrendamiento de corto y mediano plazo que en propietarios de la tierra. A su vez, un proceso frecuente en Argentina es la cesión en arrendamiento de las unidades parcelarias más pequeñas (Fernández, 2010).

Caracterizar de manera espacialmente explícita las secuencias de cultivos constituye un requerimiento clave para avanzar en el conocimiento de sus controles ambientales y humanos.

Ensayos a largo plazo muestran efectos consistentes de la rotación de cultivos sobre el rendimiento. Lund et al. (1993) observó en Estados Unidos de América reducciones en el rendimiento de hasta el 36 % en trigo, 17 % en soja y 13 % en maíz en secuencias de monocultivo de tres años frente a secuencias combinadas de estas especies. Comparaciones del rendimiento de una rotación soja-maíz frente a soja en monocultivo en Estados Unidos de América mostraron incrementos significativos en el caso de rotación en 13 de 16 años analizados con incrementos de rendimiento entre 6 y 69 % (Sindelar et al. 2015). En Pampa interior de Argentina, en tres de diez años se observaron incrementos significativos de rendimiento en una rotación maíz-soja frente a monocultivo de soja (Barraco et al. 2017). Martini y Angeli (2017), utilizando información de lotes de producción comercial de la Asociación Argentina de Consorcios Regionales de Experimentación Agrícola (AACREA) han observado caídas en el rendimiento de soja de hasta 511 kg ha^{-1} de promedio con antecesor soja frente a antecesor maíz. A su vez observaron aumentos promedio de 450 kg ha^{-1} en rendimiento con secuencias de ocho años con mayor proporción de gramíneas (maíz y trigo). Si bien estas fuentes de datos proveen información muy útil, no siempre pueden ser extrapoladas a situaciones diferentes a las del sitio de estudio (ambiente, manejo, tipo de productor, etc.).

Se pueden mencionar múltiples mecanismos que determinan variaciones en rendimiento por efecto de la secuencia de cultivos. En la Pampa Ondulada los principales cultivos sembrados son soja, maíz y trigo (MINAGRI 2017) y un esquema de rotación recomendado incluye una secuencia de tres años en los que se siembra: 1)

maíz, 2) soja de primera (único cultivo sembrado en la campaña) y 3) doble cultivo trigo-soja de segunda (Podestá et al. 2008). En comparación con maíz y trigo, la soja como único cultivo anual (soja de primera) deja muy poco rastrojo que a su vez se descompone rápidamente (Wright y Hons 2004), dejando al suelo expuesto durante gran parte del año. Esta situación, no solo aumenta la susceptibilidad a procesos de erosión (Sasal et al. 2017), sino que modificaría la disponibilidad de recursos y la dinámica del carbono en el suelo (Novelli et al. 2011), pudiendo afectar las propiedades físicas, químicas y biológicas del suelo (Karlen et al. 2006). La importancia de estos procesos variará según las condiciones de cada sitio incluyendo aspectos climáticos y edáficos, prácticas de manejo, etc.

En síntesis, aquí se plantea el problema de la falta de información existente en las principales regiones agrícolas de Argentina para una adecuada caracterización del grado de ocurrencia de rotación o monocultivo y su impacto en la producción y el ambiente. La generación de mapas anuales de cultivos con un gran detalle espacial y extensión regional, permitirá disponer de mapas de secuencias de cultivos y cuantificar de manera objetiva la ocurrencia de monocultivo y rotaciones y analizar sus patrones espaciales en relación a variables biofísicas y humanas. La generación de mapas de crecimiento o rendimiento de cultivos permitirán evaluar el impacto de las secuencias de cultivo e hipotetizar sobre los mecanismos (incidencia de variables rápidas y lentas) que lo controlan, considerando la variabilidad de situaciones presentes en un área.

Las plataformas de teledetección satelital disponibles actualmente proporcionan información espectral sobre áreas extensas con una resolución espacial y temporal que permite caracterizar lo que ocurre en lotes de cultivo a lo largo del tiempo (Bégué et al. 2018). Durante los últimos 30 años, numerosos algoritmos y metodologías se han desarrollado para relacionar la información espectral con atributos funcionales y

estructurales de los sistemas agrícolas (Tucker et al. 1981; Lobell et al. 2005; Lu y Weng 2007). Es así que es posible cartografiar tipos de cultivos en grandes áreas y evaluar su estado fisiológico de manera operativa a partir de información satelital (Deschamps et al. 2012, Wu et al. 2014). De esta manera, dependiendo de la disponibilidad de imágenes e información de campo para validación en un área, es posible generar mapas que caractericen la secuencia de cultivos de cada lote y herramientas que evalúen el estado de los cultivos a lo largo de su ciclo de crecimiento. Sin embargo, es de destacar que a pesar de disponer de plataformas satelitales desde hace décadas, la disponibilidad de información detallada y continua y con gran extensión territorial sobre la distribución y el estado de cultivos era muy escasa al inicio de esta tesis. La dificultad de acceso a las imágenes satelitales (Wulder et al. 2012), y de almacenamiento y procesamiento de grandes cantidades de información (Gorelick et al. 2017), como las requeridas para estos propósitos, fueron posibles causas del déficit de estos productos.

Existen aproximaciones globales que caracterizaron el uso del suelo mediante imágenes satelitales a diferentes resoluciones espaciales y temporales (e.g. GlobCover: extensión global a 300 m de resolución - Bontemps et al. 2011; Globeland30: extensión global a 30 m de resolución - Chen et al. 2015). Sin embargo, en general se limitaron a diferenciar usos agrícolas de no agrícolas y presentaron inconsistencias locales al comparar diversas fuentes (Fritz et al. 2011). En Argentina, se han generado mapas a escala detallada (1:500.000) de los principales usos y coberturas del suelo, sin diferenciar tipo de cultivo (e.g. INTA 2012). En el país fueron muy escasos y de reducida extensión los trabajos que llegan a diferenciar algún tipo de cultivo a nivel de lote (e.g. Caride y Paruelo, 2007; King et al. 2017). En región Pampeana no se habían encontrado trabajos que realicen mapas de cultivos anualmente en forma secuencial al

inicio de esta tesis. Solo recientemente, se han generado mapas de cultivos de las campañas 2018/2019 (de Abelleyra et al. 2019; de Abelleyra et al. 2020a), 2019/2020 (de Abelleyra et al. 2020b; MINAGRI 2022b) y 2020/2021 (de Abelleyra et al. 2021) que cubren las principales regiones agrícolas de Argentina.

El rendimiento de cultivos de grano podría estimarse a partir de registros puntuales o modelación en diversos sitios, pero esta información puede estar limitada en representatividad frente al rango de condiciones ambientales y de manejo presentes en un área (Lobell et al. 2013). Dada la cobertura territorial, temporalidad y resolución espacial de las plataformas satelitales actuales, es posible caracterizar el estado de cultivos a nivel de lote. Se trata de un aspecto más complejo aún que la identificación de cultivos dado que la definición del rendimiento se produce durante una ventana temporal relativamente corta dentro del ciclo del cultivo, y requiere disponer de imágenes en un período más acotado. Diversos investigadores han realizado con éxito estimaciones satelitales de rendimiento a nivel de departamento, provincia o estado (Becker-Reshef et al. 2010, Lobell et al. 2010); sin embargo, al realizar las estimaciones a nivel de lote se obtienen peores resultados (Reeves et al. 2005). Estimaciones a nivel de departamento permiten promediar tanto los valores de rendimiento como los valores derivados de imágenes disminuyendo la probabilidad de encontrar situaciones específicas que son difíciles de predecir.

El rendimiento puede ser determinado a partir de dos componentes: biomasa total e índice de cosecha. Este índice relaciona el rendimiento en grano con la biomasa seca aérea producida y presenta en general alta estabilidad, en particular para el cultivo de soja (Vega et al. 2000). La caracterización de variables de crecimiento de la vegetación mediante sensores remotos es dependiente de la especie y de las condiciones locales (Viña et al. 2011). Es por esto que aún se requiere desarrollar y calibrar modelos

para la estimación a escala de lote del crecimiento de cultivos y de su rendimiento según las condiciones presentes en un sitio (e.g. sistema de labranza, tipos de suelo, niveles de fertilización, etc.).

La realización de mapas series de secuencias de cultivos y que caractericen el crecimiento y rendimiento de cultivos, requiere además de conocimiento local, disponer de cierta frecuencia y continuidad en la adquisición de imágenes y el registro de observaciones a campo (e.g. tipo de cultivo, biomasa, rendimiento) distribuidas a lo largo del área de estudio. En general es escasa la disponibilidad de información de campo, un insumo fundamental para la validación de productos satelitales para el seguimiento de la agricultura (Singh Parihar et al. 2012). En este sentido, la red JECAM (Experimentos Conjuntos para la Identificación y Seguimiento de Cultivos - JECAM 2023) viene llevando a cabo sitios de validación de productos satelitales en zonas representativas de la producción agrícola mundial, entre los que se incluye la Pampa Ondulada. En ellos se identifica con gran detalle la presencia de diferentes tipos de cultivo y se realizan mediciones frecuentes de parámetros biofísicos con la finalidad de identificar tipos de cultivo y caracterizar el estado de los cultivos mediante sensores remotos. En este trabajo se utilizó gran cantidad de la información generada en el sitio JECAM San Antonio de Areco, ubicado en la Pampa Ondulada Argentina que incluyó el registro de ubicación de cultivos a lo largo de siete campañas agrícolas y la realización de mediciones de variables de crecimiento en cultivos de soja, y constituyó el área de estudio de parte de esta tesis. También se consideró información disponible a escala nacional en forma reciente (e.g. Mapa Nacional de Cultivos - de Abelleira et al. 2019; Abelleira et al. 2020; Abelleira et al. 2021) para ampliar el análisis a una mayor extensión.

1.2. Objetivos e hipótesis de trabajo

El objetivo general fue caracterizar secuencias de cultivo y evaluar su impacto en la producción y el ambiente.

Para ello se establecieron los siguientes objetivos específicos:

1. Cartografiar las secuencias de cultivos de lotes agrícolas en un sitio piloto en la Pampa Ondulada, cuantificar su ocurrencia, analizar los cambios temporales, su patrón espacial e identificar variables que controlan estos procesos.
2. Desarrollar modelos que describan variables asociadas al rendimiento de cultivos de soja a partir de información satelital.
3. Analizar el efecto de las diferentes secuencias de cultivo observadas en el sitio piloto sobre el crecimiento de cultivos de soja y el carbono orgánico del suelo y proponer posibles mecanismos involucrados.
4. Extender la caracterización de secuencias de cultivos y sus posibles controles a escala nacional.

Hipótesis

Hipótesis 1. La planificación de la secuencia de cultivos integra factores biofísicos y humanos. La riqueza de especies en la rotación está controlada por variables biofísicas (aptitud de los suelos, topografía, clima) mientras que la dominancia de una especie en la rotación está controlada por factores humanos (e.g. régimen de tenencia de la tierra, tipo de productor).

Predicción 1: En lotes con menores restricciones biofísicas la cantidad de especies en la rotación será mayor que en lotes con limitantes edáficas, topográficas o climáticas. La frecuencia de soja de primera será mayor en lotes arrendados y cuanto mayor sea la diferencia en margen bruto entre soja de primera y otros cultivos.

Hipótesis 2: En sistemas agrícolas con bajo nivel de insumos la importancia de los mecanismos de transmisión temporal de información es alta y dependerá en gran medida de su historia de manejo.

Predicción 2: Cultivos con relativamente baja utilización de insumos como la soja sembrada en Argentina, dependerán en gran medida de las condiciones del sitio generadas por la historia de uso. De esta manera se espera encontrar una fuerte asociación entre la situación presente y la pasada, mostrando un gran efecto en el crecimiento o rendimiento de la secuencia de cultivos previa.

Hipótesis 3: Las características de cada cultivo –en términos de cantidad de rastrojo, uso del agua, etc.- así como las prácticas de manejo asociadas y su secuencia temporal generan alteraciones en el ciclo hidrológico y biogeoquímico que pueden generar efectos a largo plazo.

Predicción 3: Distinta proporción de soja de primera en una secuencia de cultivos modificará en distinta proporción a variables lentas o de largo plazo (e.g. contenido y distribución del carbono en el suelo, capacidad de retención hídrica o disponibilidad de nutrientes) que pueden limitar el crecimiento futuro de un cultivo. La menor entrada de carbono en sistemas con gran proporción de soja de primera disminuirá el nivel de carbono del suelo. La disminución excesiva del nivel de carbono podrá afectar la estructura del suelo y disminuir su capacidad de acumulación de agua.

1.3. Estructura de la tesis

La tesis, dispone de una estructura de seis capítulos, uno introductorio general (Capítulo I), tres capítulos en los que se describen secuencias de cultivos (Capítulo II), se generan modelos de crecimiento (Capítulo III) y se evalúa el impacto de las secuencias (Capítulo IV) en un sitio piloto de la Pampa Ondulada, un capítulo en que se expanden los principales análisis de esta tesis a escala nacional (Capítulo V), y un capítulo final de conclusiones generales (Capítulo VI).

El capítulo I incluye la introducción general, los objetivos y las hipótesis planteadas. Los capítulos II a IV incluyen: i) la descripción de las rotaciones en el sitio piloto y su distribución espacial y controles (Capítulo II); ii) la generación de modelos que describen el crecimiento de soja en la región a partir de sensores remotos ópticos y de RADAR (Capítulo III) y iii) la estimación del impacto de diferentes secuencias de cultivos en el crecimiento de cultivos de soja y el carbono del suelo (Capítulo IV). El capítulo IV describe el impacto de las rotaciones en el sitio piloto. Incluye la utilización de mapas de secuencias de cultivos generados en el segundo capítulo y el uso de los modelos desarrollados en el tercer capítulo para estimar el crecimiento de soja a partir de información satelital. El quinto capítulo considera los avances obtenidos a lo largo de los capítulos anteriores, y expande algunos de los análisis realizados en esta tesis a una escala espacial mayor haciendo uso de información derivada de tres campañas agrícolas del Mapa Nacional de Cultivos y que permiten analizar secuencias de cultivos a lo largo de las principales regiones agrícolas de Argentina. El último capítulo describe las conclusiones generales de la tesis.

Capítulo II

Rotaciones en la Pampa Ondulada: Caracterización, patrones espaciales y posibles controles

2.1. Introducción

La planificación de siembra de cultivos es un aspecto crítico del manejo agronómico con importantes consecuencias económicas y ambientales a corto y largo plazo. Numerosos estudios han mostrado el efecto de diferentes secuencias de cultivos sobre el rendimiento (Lund et al. 1993; Meyer-Aurich et al. 2006; Lemke et al. 2012; Sindelar et al. 2015), el contenido de carbono del suelo (Karlen et al. 2006) y el riesgo de infestación con malezas y enfermedades o plagas (Ulber et al. 2009). Desde una perspectiva de ecosistema, una descripción de secuencias de cultivos junto con su patrón espacial podría ser indicadora de provisión de servicios ecosistémicos o, alternativamente de riesgo de degradación (Glavan et al. 2015). A su vez, los cambios en las secuencias de cultivos, podrían evidenciar diferente capacidad adaptativa a controles externos como el cambio climático o la volatilidad en el precio de *commodities*, entre otros.

La elección de una especie de cultivo para su siembra es el resultado de un proceso de toma de decisión que depende de múltiples variables que se presentan a diferentes escalas temporales y espaciales, como la aversión al riesgo, el conocimiento previo, la capacidad de planificación a largo plazo, o disponibilidad de capital - monetario, natural, infraestructura -, etc. A su vez, pueden existir objetivos competitivos entre sí como la maximización del ingreso actual y la estabilidad en el ingreso a largo plazo.

Para obtener el mayor beneficio de la agricultura y minimizar sus consecuencias ambientales, se requiere mejorar el conocimiento sobre qué motiva la selección de diferentes secuencias de cultivos, y conocer el impacto de ello. Esto permitirá proponer y generar incentivos para el desarrollo de buenas prácticas agrícolas como la rotación de

cultivos. Para cumplir con este objetivo a nivel regional es necesario disponer de información básica que brinde una descripción precisa y representativa de cuáles son las secuencias de cultivos más frecuentes en un área.

Los sensores remotos son comúnmente utilizados para la generación de mapas de diferentes coberturas y usos del suelo debido a que registran áreas extensas de manera periódica. Sin embargo, la caracterización de tipos de cultivos y secuencias de éstos, requiere de información a nivel de especie, que representa un desafío adicional a las clasificaciones de coberturas usuales basadas en imágenes satelitales (Bontemps et al. 2011; Chen et al. 2015). De hecho, la generación de mapas de cultivos incrementa la demanda en temporalidad, resolución espectral y disponibilidad de información de campo, en comparación con la discriminación de clases más genéricas como la cobertura agrícola sin diferenciar o la discriminación de simples vs. dobles cultivos. Por ejemplo, si solamente se quieren separar cultivos de invierno y de verano, podrían ser diferenciados con al menos dos imágenes (una en cada estación) (Guerschman et al. 2003); pero para la caracterización de diferentes cultivos de verano por ejemplo, se requiere mucha mayor frecuencia de adquisiciones de imágenes (Deschamps et al. 2012; Foerster et al. 2012). La generación de series de mapas de cultivos a nivel de lote es también un desafío en relación a la disponibilidad de imágenes satelitales libres de nubes durante períodos críticos.

La región Pampeana, la principal región agrícola de Argentina, ha mostrado cambios significativos durante las últimas décadas (Paruelo et al. 2005; Viglizzo et al. 2011; Piquer Rodriguez et al. 2018). Principalmente se ha observado una expansión de la agricultura a tierras dedicadas a la ganadería y un notable incremento del área sembrada con el cultivo de soja. La expansión de la soja puede estar explicada por diversos factores: económicos, como el cambio en su precio internacional; técnicos,

como la disponibilidad de paquetes tecnológicos con soja resistente a glifosato y el desarrollo de sistemas de siembra directa; y socio-políticos, como cambios el régimen de tenencia de la tierra, y aspectos impositivos. Es de destacar que a nivel nacional, el aumento en la superficie de soja se observa hasta el año 2015, presentando una leve disminución durante los años posteriores, junto a un leve aumento del área de maíz y de trigo (SAGyP 2023).

La expansión del cultivo de soja durante las últimas décadas ha generado preocupación social sobre el riesgo de monocultivo. Sin embargo, las menciones al monocultivo de soja se basan en estadísticas a nivel de departamento -que no identifican lo que ocurre en cada lote-, en encuestas o en fuentes subjetivas de información (e.g. Barros et al. 2015; Haro Sly 2017). Una descripción cuantitativa y espacialmente explícita de las secuencias de cultivos permitirá una estimación objetiva del grado de monocultivo de soja, y permitirá analizar posibles controles de la rotación de cultivos y evaluar el impacto en el crecimiento y rendimiento de cultivos y en el ambiente agrícola.

Se propusieron entonces los siguientes objetivos en este capítulo:

- i) Caracterizar las secuencias de cultivos a través de la generación de mapas anuales de tipo de cultivo en la Pampa Ondulada
- ii) Analizar la distribución espacial de diferentes patrones de rotación y explorar sus posibles controles.

2.2. Materiales y Métodos

2.2.1. Área de estudio

El sitio de estudio se ubica en la Pampa Ondulada, una subregión de la región Pampeana Argentina (Figura 2.1) que dispone de pendientes leves (menores a 3 %) y abundante presencia de ríos y arroyos. Los suelos son profundos y con alto contenido de materia orgánica (Leon 1991). El clima es templado con un régimen de precipitaciones homogéneo a lo largo del año y un promedio de 1000 mm anuales. Los cultivos dominantes son soja, maíz y trigo. Soja y maíz se siembran principalmente como cultivo único en toda la estación de crecimiento. El trigo generalmente es seguido de un cultivo de soja, presentando en este caso dos cultivos por campaña (trigo-soja). El maíz se siembra como cultivo único en los meses de septiembre y octubre (maíz temprano) o en diciembre y enero (maíz tardío). El sistema de siembra dominante en la región es la siembra directa, por el cual se realiza una única labranza al suelo de poca profundidad al momento de la siembra. El tamaño de lote promedio es de 20 ha y presenta gran variabilidad (Waldner et al. 2016). Las áreas no agrícolas están dominadas por forrajes incluyendo pasturas y pastizales naturales (Waldner et al. 2016).

El área de estudio es parte de la red JECAM para el monitoreo de la agricultura a escala global (JECAM 2023), que consta de un conjunto de sitios piloto distribuidos en las principales regiones agrícolas del mundo con la finalidad de validar productos derivados de sensores remotos como mapas de cultivos y de rendimiento. El límite del área definida para este trabajo es el resultado de la intersección de las múltiples escenas de plataformas satelitales adquiridas durante el período de estudio (junio de 2010 a mayo de 2017 - Cuadro 2.1, Figura 2.1), sobre la cual se realizaron relevamientos a campo en cada una de las campañas.

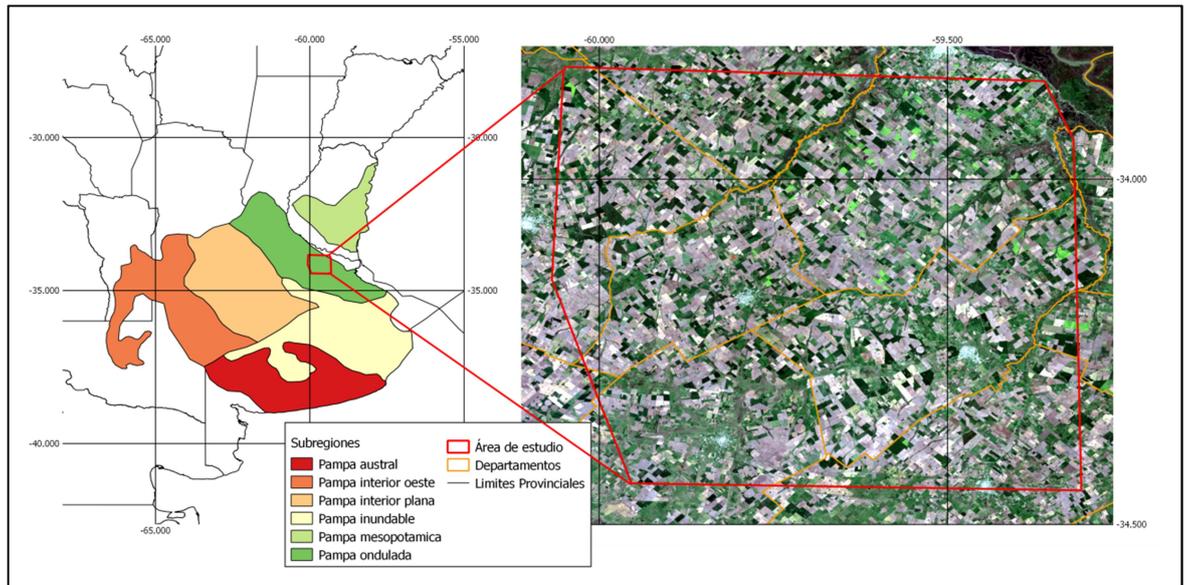


Figura 2.1. Área de estudio delimitada por la intersección de las escenas satelitales adquiridas durante el período considerado (2010-2017). Izquierda: Subregiones de la región Pampeana Argentina (Oyarzabal et al. 2018). Derecha: Imagen del satélite Sentinel 2- Agencia Espacial Europea (06/09/2016).

Cuadro 2.1. Número de escenas de las diferentes plataformas satelitales utilizadas en el área de estudio durante las siete campañas agrícolas consideradas (2010-2017).

Campaña	RESOURCESAT 1	DEIMOS	DMCii	Landsat 5	Landsat 8	Sentinel 2	SPOT 4	Total
2010/2011				6				6
2011/2012	1	1		2			2	6
2012/2013	8		7					15
2013/2014		3	1		7			11
2014/2015			3		12			15
2015/2016					3	4		7
2016/2017					9	6		15
Total	9	4	11	8	31	10	2	75

2.2.2. Clasificación de cultivos y generación de mapas de secuencias de cultivos

Se generaron mapas de cultivos durante siete campañas consecutivas: 2010/2011, 2011/2012, 2012/2013, 2013/2014, 2014/2015, 2015/2016 y 2016/2017. El período considerado para cada campaña estuvo entre el 1 de junio y el 31 de mayo del año siguiente. Se definieron cinco clases: 1) soja de primera (cultivo único), 2) trigo-soja (doble cultivo), 3) maíz temprano (cultivo único sembrado en septiembre u octubre), 4) maíz tardío (cultivo único sembrado en diciembre o enero) y 5) no agrícola (principalmente pasturas y pastizales naturales). Maíz tardío fue considerado una clase separada de maíz temprano a partir de la campaña 2013/2014 para facilitar su separabilidad. Para el resto del análisis, maíz temprano y tardío fueron considerados como una única clase (maíz).

Las imágenes satelitales obtenidas incluyeron aquellas disponibles libremente como Landsat 5 TM, Landsat 8 OLI y Sentinel 2, como así también imágenes obtenidas a través de la red JECAM: DMCii, DEIMOS 1, RESOURCESAT 1 AWIFS y SPOT 4 HRVIR (Cuadro 2.1). Las imágenes Landsat 5 TM y Landsat 8 OLI fueron descargadas del sitio del Servicio Geológico de los Estados Unidos de América (USGS 2023). Las imágenes Sentinel 2 fueron descargadas a través de la plataforma *Google Earth Engine* (Gorelick et al. 2017). Estas imágenes fueron descargadas con el procesamiento de ortorectificación, mientras que el resto de las imágenes incluyó la georeferenciación manual con un error de 1 píxel. Las imágenes fueron procesadas para obtener valores de reflectancia a tope de la atmósfera siguiendo la metodología de Chander et al. (2009) cuando fue necesario (i.e. para DMCii, DEIMOS 1 y RESOURCESAT-1 AWIFS). Todas las bandas de reflectancia del rango visible e infrarrojo disponibles fueron utilizadas para la clasificación. Dado que la resolución espacial de los diferentes sensores varió entre 10 (SPOT 4, Sentinel 2) y 56 m (RESOURCESAT-1 AWIFS), las

imágenes fueron remuestreadas a un tamaño de píxel común de 30 m, siguiendo la resolución de Landsat que fue la fuente de imágenes más frecuente.

Se obtuvo información de campo, necesaria para el entrenamiento y validación de las clasificaciones supervisadas, a partir de numerosos relevamientos llevados a cabo durante las siete campañas agrícolas en diferentes momentos del año y cubriendo los principales caminos del área de estudio. Se registraron puntos georeferenciados correspondientes a lotes de cultivo y otros usos no agrícolas. Posteriormente se generaron polígonos dentro de los lotes con el apoyo de imágenes de *Google Earth*. El Cuadro 2.2 muestra el número de lotes registrados de las diferentes clases durante cada campaña agrícola.

Cuadro 2.2. Número de polígonos (lotes) registrados para cada clase durante las siete campañas agrícolas consideradas. Clases: M1, maíz temprano; M2, maíz tardío, S1, soja de primera; TS, doble cultivo trigo-soja, FORR, no agrícola.

Campaña	M1	M2	S1	TS	FORR	Total
2010/2011	57	-	72	137	87	356
2011/2012	28	-	92	115	101	318
2012/2013	49	-	138	49	58	323
2013/2014	60	36	194	81	113	484
2014/2015	72	53	349	117	294	885
2015/2016	48	34	451	69	350	952
2016/2017	89	19	365	113	449	1035

2.2.2.1 Metodología de clasificación

Se generó un conjunto de clasificaciones para cada campaña agrícola basados en métodos de clasificación supervisados. Una vez realizados los mapas de cultivos de

cada campaña, se generó un mapa de secuencias de cultivos para poder analizar la ocurrencia de monocultivo y rotaciones.

Se utilizaron los siguientes métodos de clasificación: 1) Máxima Verosimilitud, 2) Regresión Logística Multinomial, 3) Máquinas de Soporte de Vectores, 4) Bosques Aleatorios, y 5) Redes Neuronales. Las clasificaciones fueron implementadas a nivel de pixel utilizando el paquete del proyecto R denominado *rasclass* con sus parámetros configurados por defecto (La Rosa y Wiesmann 2013). El método de Máxima Verosimilitud genera una distribución de probabilidad normal para cada capa de información y clase, y asigna a cada píxel la clase con mayor probabilidad de pertenencia. La Regresión Logística Multinomial define probabilidades de pertenencia a cada clase ajustando una función logística a partir de los valores de cada capa. Las Máquinas de Soporte de Vectores identifican hiperplanos de separación de las muestras (donde cada capa es una dimensión), y optimiza los que mejor separan las muestras dentro de las clases definidas.

Las Redes Neuronales consisten en una red de funciones interrelacionadas donde cada una puede recibir el resultado o ser la entrada de otra función. Los parámetros de las funciones son optimizados luego de varias iteraciones donde se evalúa el resultado de la clasificación. El método de Bosques Aleatorios genera múltiples árboles de decisión para realizar clasificaciones. Cada árbol de decisión se entrena con una selección de muestras y de variables (capas) levemente distinta. El resultado de la clasificación es un ensamble (e.g. votación por mayoría) de los resultados de la clasificación de cada árbol.

Del total de datos obtenidos de relevamientos de campo de cada campaña, se separó el 25 % para una validación final, o sea que no fueron utilizados en ningún

entrenamiento de los clasificadores. Con el resto de los datos se hicieron 5 selecciones aleatorias del 75 % de los datos remanentes para entrenar cada uno de los clasificadores, resultando un total de 25 clasificaciones por cada campaña (Waldner et al. 2016). Se obtuvo una clasificación final por cada campaña mediante votación por mayoría de las 25 clasificaciones, o sea seleccionando la clase más frecuente en cada píxel. Se aplicó un filtro espacial de mediana para reducir la presencia de píxeles aislados de una clase distinta a los píxeles circundantes. El resultado de la clasificación fue evaluado a través de los índices exactitud general, exactitudes de usuario y productor y el índice *G-mean* (Waldner et al. 2019). La exactitud general indica el total de aciertos en la clasificación (concordancia de clase) con respecto al total de datos utilizados en la validación. La exactitud de usuario indica para cada clase, cuántos de los datos clasificados coincidieron con los datos de validación. La exactitud de productor indica el total de casos en que los datos de validación de cada clase concordaron con el mapa generado. *G-mean* se estimó de la siguiente manera:

$$G - mean = \left(\prod_{i=1}^j PA_i \right)^{\frac{1}{j}} \quad (1)$$

Donde: PA es la exactitud de productor de cada clase i , y j es el número de clases.

Se aplicó una máscara de cuerpos de agua, ríos y áreas urbanas generadas por el Instituto Geográfico Nacional (IGN 2023).

2.2.3. Análisis de datos

Se analizó la ocurrencia de diferentes secuencias de cultivos durante el período 2010-2017. Considerando las múltiples posibilidades de secuencias de cultivos a lo largo del tiempo, se priorizaron tres secuencias de cultivos:

1) monocultivo de soja (i.e. siembra de soja de primera durante dos o más años consecutivos)

2) rotación recomendada: ciclo de rotación de tres años recomendada para la zona de estudio (Podestá et al. 2008):

Primer año: maíz

Segundo año: soja de primera (cultivo único)

Tercer año: doble cultivo trigo-soja

3) rotación de cultivos de verano (Aramburu Merlos et al. 2015):

Primer año: maíz

Segundo año: soja de primera (cultivo único)

Se contabilizó y se generó un mapa del número de años en que cada uno de estos casos fue observado. Para secuencias como la rotación recomendada y la rotación de cultivos de verano, se contabilizó el número de períodos (casos) en que ocurrió alguna de las secuencias mencionadas. Por ejemplo, las secuencias maíz / soja de primera y soja de primera / maíz fueron contabilizadas como casos de rotación de cultivos de verano. En consecuencia, si la asignación a un lote alternó entre maíz y soja de primera durante las siete campañas, se contabilizaron siete años de rotación de cultivos de verano. A su vez, se consideró que la rotación puede iniciar en cualquiera de las campañas (e.g. si después de una soja de primera se identificó trigo-soja se contabilizó como dos años de rotación recomendada). También se realizó una comparación de la ocurrencia de los casos observados, en relación a lo esperado en una selección aleatoria de secuencias de cultivos. Esto se calculó considerando una probabilidad de siembra de

cualquiera de los 3 cultivos (soja de primera, maíz o trigo-soja) de 1/3, multiplicado por la cantidad de campañas agrícolas.

Se realizó un análisis espacial de puntos para lo cual se consideró la ubicación del centroide de lotes clasificados como monocultivo y de lotes clasificados como rotación recomendada. Para delinear los lotes se utilizó el método de segmentación *MeanShift* (Grizzonet et al. 2017) que fue aplicado utilizando el mapa de secuencias de cultivos como entrada. Se asumió que los polígonos generados por la segmentación pueden ser considerados como unidades de manejo o lotes. Se evaluó si la ubicación de los casos de monocultivo y rotación recomendada estaba agrupada o era aleatoria utilizando una función de correlación de pares (PCF – Stoyan y Stoyan 1994). Así se generó una función de densidad que indica la probabilidad de encontrar dos puntos a cada distancia definida entre pares de puntos. Un patrón de distribución aleatorio muestra el valor de densidad de probabilidad de uno, mientras que valores mayores indican agrupamiento, y valores menores, un patrón de repulsión. Este análisis se realizó utilizando el paquete del proyecto R *spatstat* (Baddeley y Turner 2005).

También se analizó la distribución espacial de casos de monocultivo y rotación recomendada en relación a otras variables distribuidas espacialmente y variables económicas. Se identificaron para ello secuencias con cinco o más períodos de monocultivo de soja (repetición del cultivo en siembras sucesivas), y secuencias con cinco o más años de rotación recomendada. Se utilizó un análisis de Regresión Logística (Luoto et al. 2002) para identificar si existe asociación entre variables cuantitativas y una variable categórica como la ocurrencia de un tipo de secuencia de cultivos. Las variables analizadas fueron Capacidad de Uso del suelo, elevación del terreno y tamaño de unidades catastrales. La Capacidad de Uso del suelo representa el grado de limitación de un suelo para su uso agrícola o ganadero y fue obtenida de un

mapa digital a escala 1:50.000 (INTA 2009). Valores más bajos de Capacidad de Uso representan sitios con mayor aptitud agrícola. Los datos de elevación del terreno fueron obtenidos del modelo digital de elevación del SRTM (Farr et al. 2007). Valores con mayor elevación son indicadores de zonas de loma con menores problemas de drenaje y suelos más profundos. El tamaño de unidades catastrales se obtuvo a partir de los planos de parcelas catastrales de la provincia de Buenos Aires del año 2016. Se utilizó esta variable como indicadora del tamaño del establecimiento productivo, aquí se asume que guarda una relación con el grado de capitalización del productor agropecuario. La información obtenida en formato vectorial, se rasterizó para incluirla en el análisis espacial de puntos. También se utilizó información no espacializada de variación de precios internacionales de granos derivada de FAOSTAT (2018). Se analizó la relación entre el área de los cultivos de soja, maíz y trigo durante el período analizado y el precio de los granos en el año previo a la siembra de los cultivos.

2.3. Resultados

2.3.1. Clasificación de cultivos

Durante las siete campañas agrícolas consideradas las exactitudes generales fueron mayores al 85 %, e incluso la mayoría de los años fue mayor al 90 % (Cuadro 2.3). En general las clases de maíz fueron las que mostraron exactitudes de productor más bajas, mostrando confusión entre maíz temprano tardío y entre ellos y soja de primera. Las exactitudes de soja de primera se incrementaron a partir de 2013/2014, reflejando menores problemas de confusión con maíz cuando se incluyó maíz tardío como clase. El índice *G-mean* varió entre 0,79 y 0,93, mostrando los menores valores durante las campañas 2011/2012 y 2016/2017 (Cuadro 2.3).

Cuadro 2.3. Exactitudes de clasificación obtenidas durante cada campaña agrícola.

Clases: M1, maíz temprano; M2: maíz tardío; S1; soja de primera; TS, doble cultivo trigo-soja; FORR, no agrícola.

Campaña	2010/ 2011	2011/ 2012	2012/ 2013	2013/ 2014	2014/ 2015	2015/ 2016	2016/ 2017
Exactitud general	0,91	0,88	0,87	0,96	0,90	0,93	0,94
<i>G-mean</i>	0,86	0,80	0,84	0,93	0,85	0,89	0,79
M	0,87	0,54	0,76				
M1				0,97	0,69	0,78	0,86
M2				0,77	0,79	0,89	0,39
S1	0,98	0,96	0,92	0,99	0,92	0,97	0,99
TS	0,96	0,90	0,82	0,98	0,93	0,86	0,95
FORR	0,66	0,90	0,85	0,94	0,93	0,94	0,97
M	1,00	0,98	0,86				
M1				0,99	0,90	0,71	0,86
M2				1,00	0,72	0,99	0,89
S1	0,78	0,76	0,87	0,97	0,95	0,95	0,96
TS	0,96	0,96	0,87	0,94	0,83	0,94	0,99
FORR	0,95	0,93	0,85	0,92	0,93	0,95	0,93

Los mapas de cultivo no mostraron una tendencia clara en el área sembrada de los diferentes cultivos. El área de soja de primera mostró aumentos hasta la campaña 2012/2013, luego una estabilización y una disminución durante la campaña 2016/2017. El área de trigo-soja mostró valores más bajos durante las últimas cinco campañas (Figuras 2.2 y 2.3A). Se observó una leve tendencia positiva del área de maíz asociado a una mayor ocurrencia de maíz tardío durante los últimos años. La variación temporal en

el área de soja de primera siguió el patrón de los precios internacionales, con lo que se encontró una correlación positiva (r^2 aj. 0,5, $p < 0,01$) entre el área de soja de primera y el precio de la soja durante el año previo (Figura 2.3B). El área de maíz y de trigo-soja no mostró asociación con los precios internacionales.

2.3.2. Análisis de secuencias de cultivos

La Figura 2.4 muestra la frecuencia de ocurrencia de tres secuencias de cultivos: monocultivo de soja, rotación recomendada y rotación de cultivos de verano. La práctica de monocultivo de soja fue la más frecuente entre las tres (Figura 2.4). Sitios con alto grado de monocultivo de soja se observan concentrados en ciertas áreas (noroeste, sudoeste y centro). Sitios con varios años de rotación recomendada se pueden observar al sudeste y con un patrón más disperso en el resto del área de estudio. La rotación solo con cultivos de verano fue bastante infrecuente y dispersa.

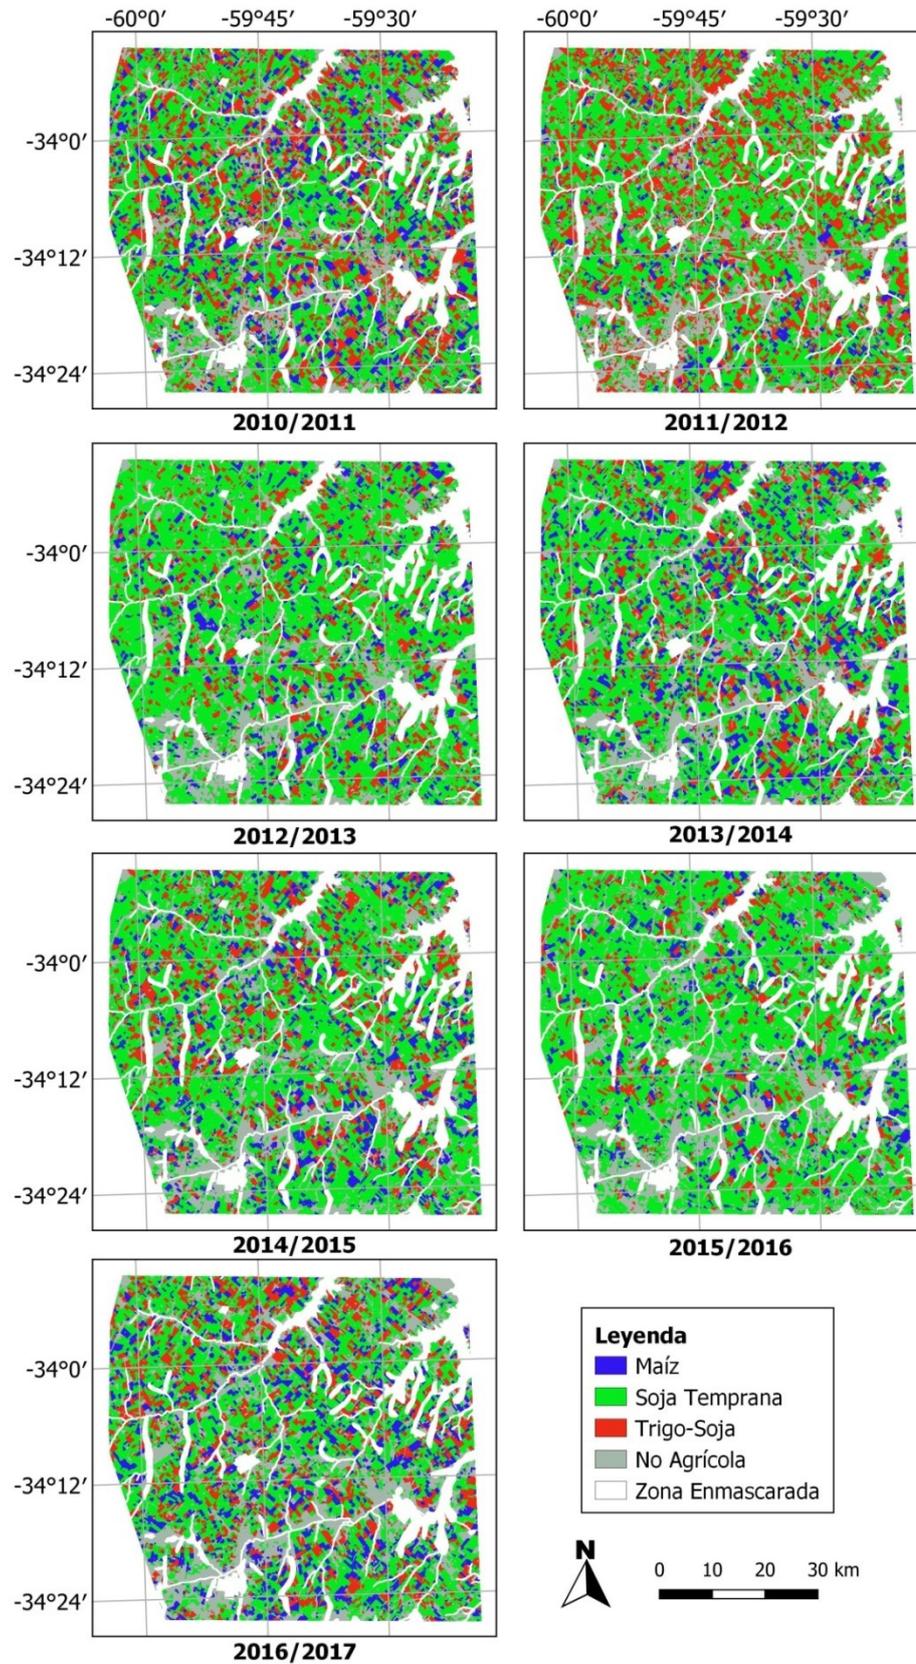


Figura 2.2. Mapas de cultivos para las siete campañas agrícolas consideradas. Las zonas enmascaradas incluyen ríos, cuerpos de agua y zonas urbanas.

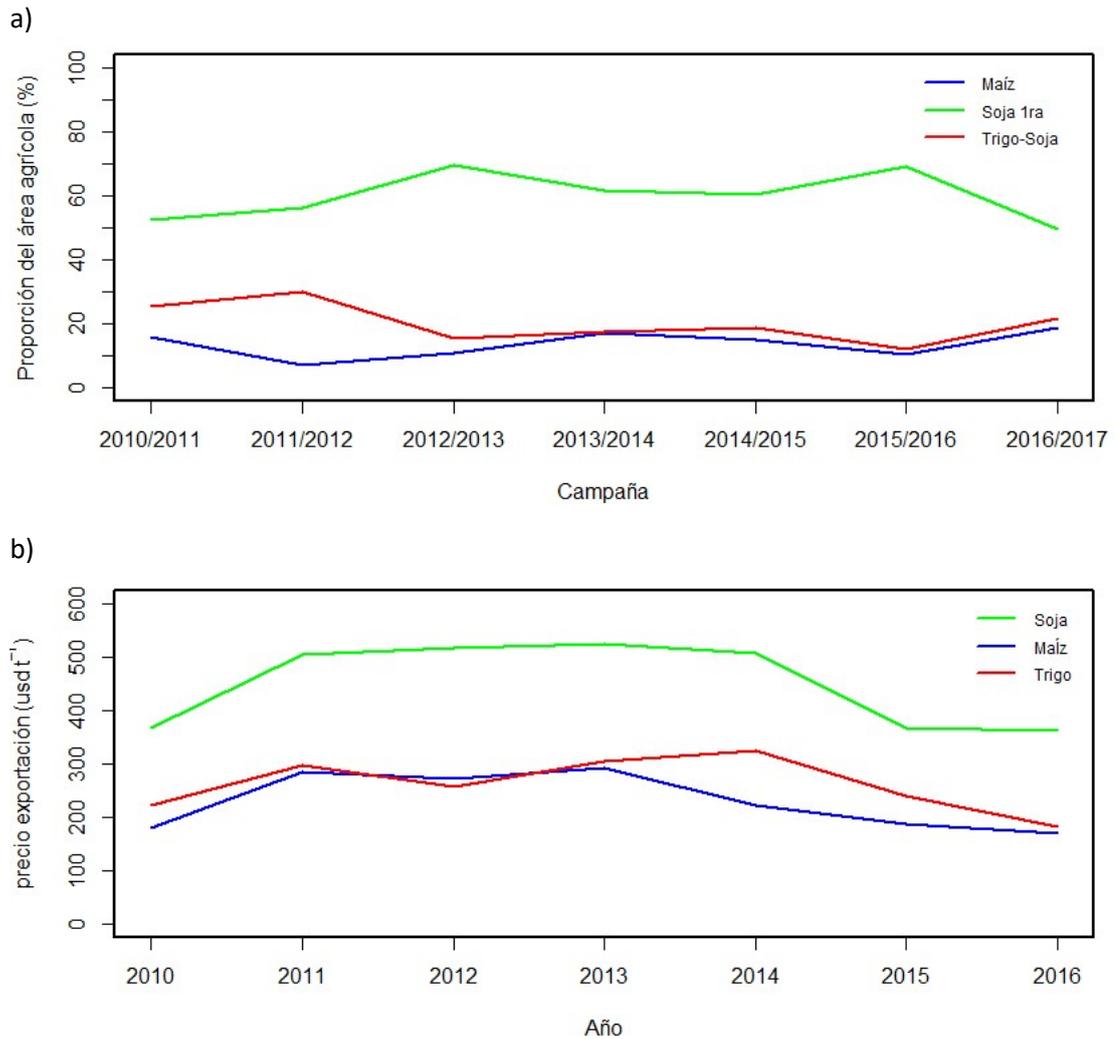


Figura 2.3. A) Área de las clases de cultivos clasificadas, expresada como proporción del área agrícola (sin considerar áreas no agrícolas) para las siete campañas agrícolas consideradas; B) Precio de exportación de cultivos (promedio anual) de maíz, soja y trigo durante el período de estudio. Fuente: FAOSTAT (2018).

Si bien se observaron casos con períodos prolongados tanto de monocultivo de soja, como de rotación recomendada; las situaciones más frecuentemente observadas incluyeron situaciones intermedias con períodos más cortos de rotación y de monocultivo de soja (Figura 2.5). Cerca del 80 % del área agrícola presentó al menos dos años consecutivos con soja de primera (79,8 %) o dos años de alguna de las secuencias de rotación recomendada (83,2 %). En consecuencia, un 20,2 % del área

cultivada nunca presentó monocultivo de soja (no tuvo años consecutivos con soja de primera) y un 16,8 % nunca presentó la rotación recomendada (i.e. no se detectaron años consecutivos con alguna de estas secuencias). Cerca del 25 % del área presentó al menos cinco años consecutivos de con soja de primera, mientras que cerca del 15 % del área presentó cinco o más años consecutivos con rotación recomendada. El monocultivo de soja a lo largo de las siete campañas fue observado en el 5 % del área, mientras que en el 2,5 % del área se observó la rotación recomendada a lo largo de las siete campañas analizadas. Otras combinaciones de secuencias como la rotación de cultivos de verano fue mucho menos frecuente (0,5 %). La ocurrencia de los tres grupos de secuencias identificados (monocultivo de soja, rotación recomendada y de cultivos de verano) fue mucho mayor que la probabilidad de ocurrencia de una secuencia de cultivos al azar (Figura 2.5).

Un análisis de transiciones (i.e. el análisis de secuencias de dos años) mostró que la siembra de soja de primera después de maíz ocurrió en más del 80 % del área de maíz durante todos los períodos considerados (Figura 2.6). Otras transiciones ocurrieron en mucha menor proporción. El área que pasó de trigo-soja a soja de primera disminuyó considerablemente entre 2012 y 2013 y se mantuvo baja durante el resto de las campañas, al mismo tiempo que soja de primera se volvió más frecuente (Figura 2.3A; Figura 6). Por el contrario, la transición de trigo-soja a maíz aumentó luego de 2012/2013. Secuencias repetidas de dos años de soja de primera fueron observadas mayormente en la mitad del período de estudio, momentos en que el precio de la soja fue mayor. Se observaron también incrementos en las secuencias trigo-soja a maíz y soja de primera a trigo soja en concordancia con incrementos en el área de maíz y trigo-soja durante la última campaña considerada (2016/2017).

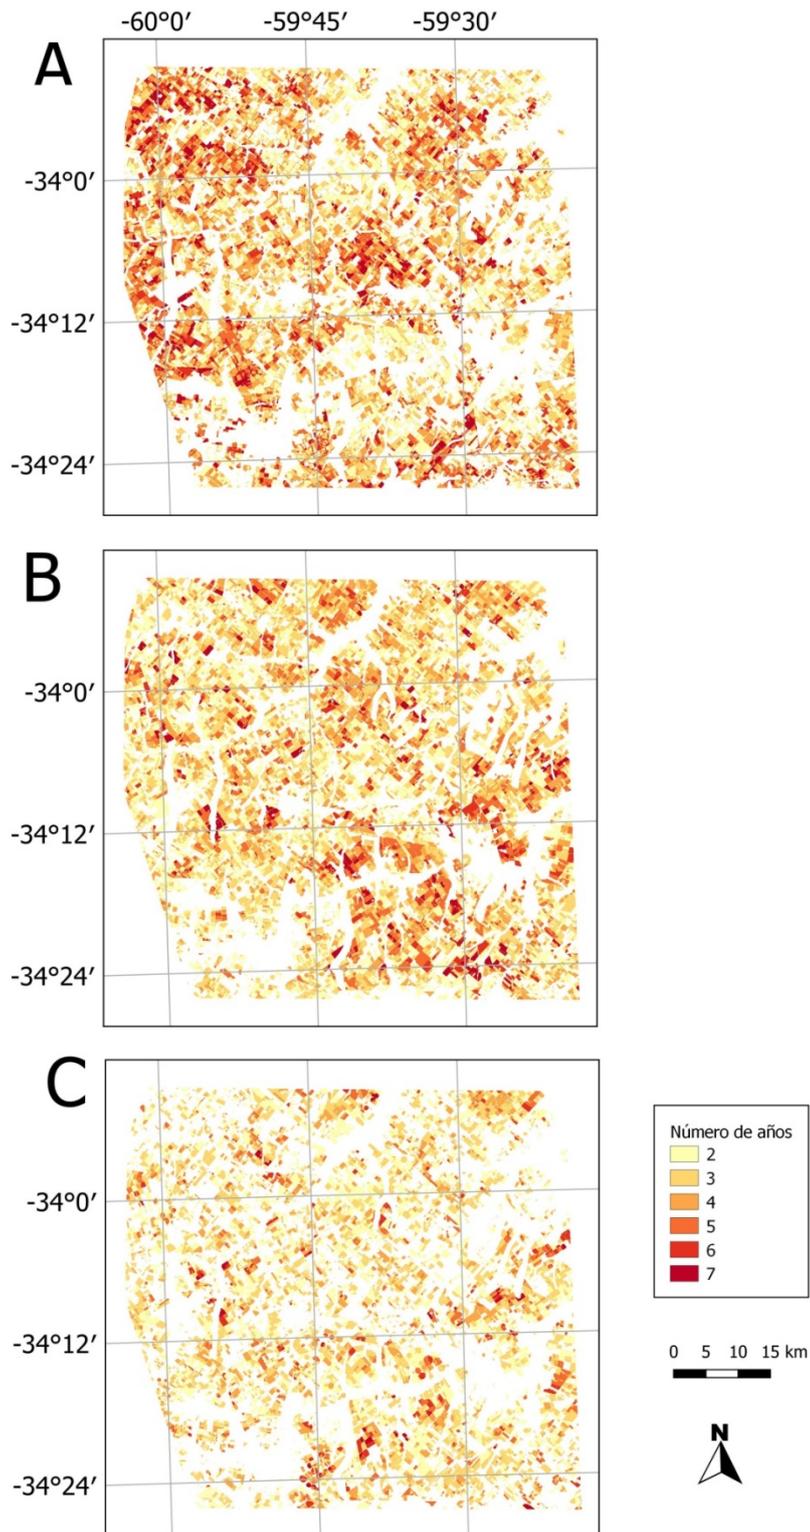


Figura 2.4. Número de años consecutivos con las secuencias de cultivo analizadas: A) monocultivo de soja; B) rotación recomendada (maíz / soja de primera / trigo-soja); C) rotación de cultivos de verano (maíz / soja de primera).

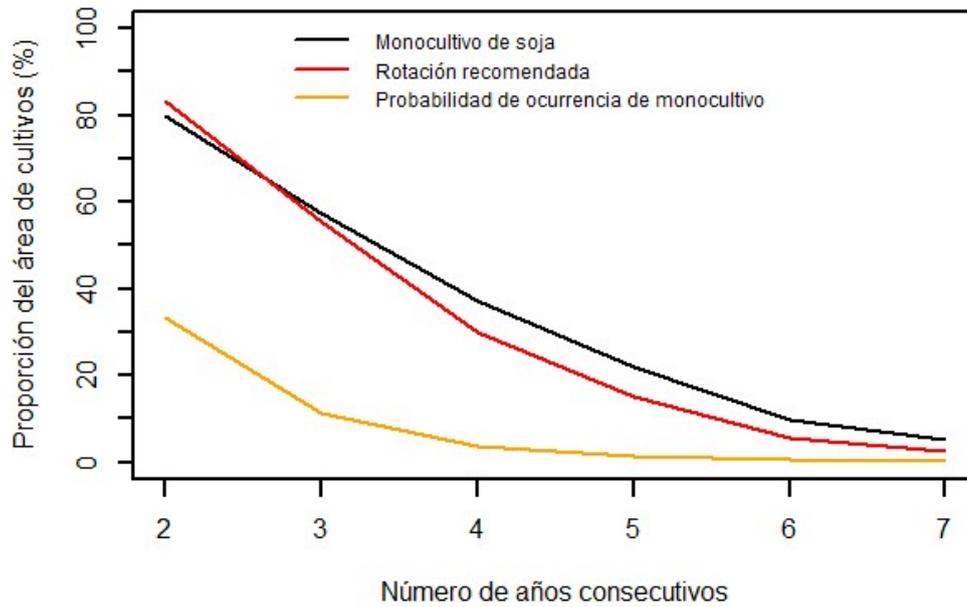


Figura 2.5. Área identificada con diferentes secuencias de cultivos durante un número creciente de años consecutivos expresada como proporción del área agrícola (sin considerar áreas no agrícolas). Línea negra, monocultivo de soja; línea roja, rotación recomendada, línea naranja, probabilidad de ocurrencia aleatoria de monocultivo considerando tres posibles casos de ocupación: maíz, soja de primera y trigo-soja.

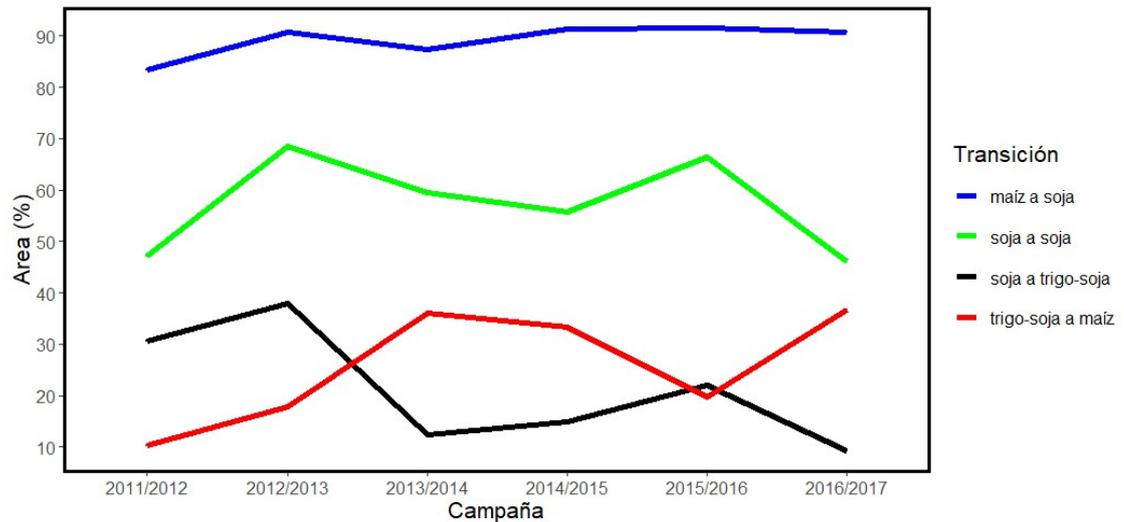


Figura 2.6. Área de transición de cultivos a lo largo de diferentes sub-períodos de dos años (expresados como el porcentaje del área del cultivo en la segunda campaña con respecto al cultivo en la primera campaña). Soja de primera después de maíz (verde); soja de primera después de soja de primera (negro); trigo-soja después de soja de primera (rojo); maíz después de trigo-soja (azul). El eje x muestra la última campaña de cada sub-período.

La Figura 2.7 muestra los valores de PCF para diferentes distancias donde se observaron los casos de: 1) sitios con cinco o más años de monocultivo de soja y 2) sitios con cinco o más años de secuencias de rotación recomendada. Ambos casos mostraron un patrón de agrupamiento a cortas distancias y un patrón cercano al aleatorio a largas distancias. Los valores de PCF de monocultivo de soja se estabilizan alrededor de 1 (distribución aleatoria) antes de alcanzar los 1000 metros de distancia; mientras que la rotación recomendada mostró valores estables de PCF cerca de los 2000 metros.

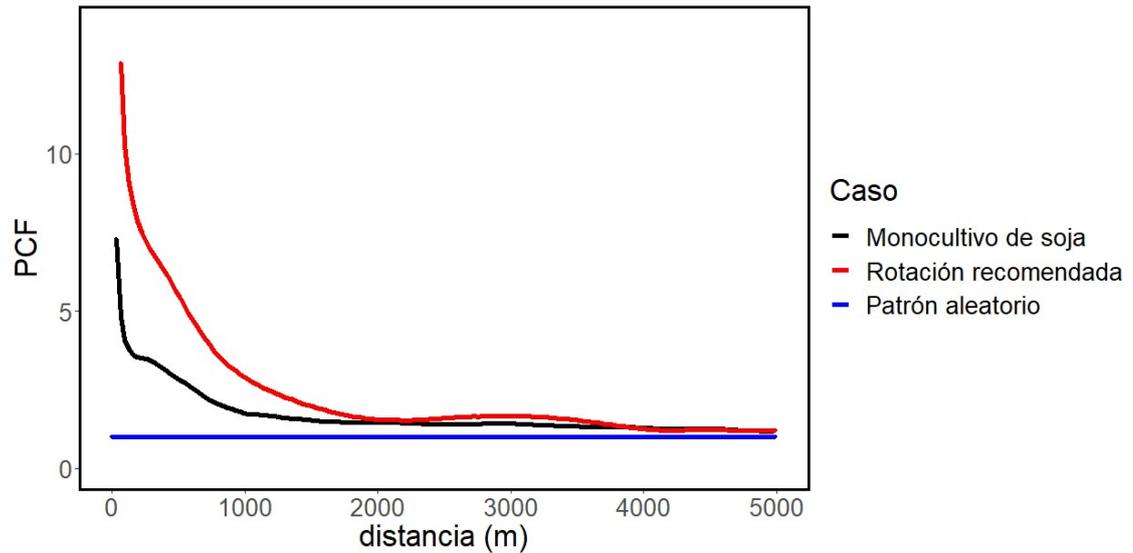


Figura 2.7. Función de Correlación de Pares (PCF) para los casos de cinco o más años de monocultivo de soja (línea negra) y de rotación recomendada (línea roja). Línea azul representa el valor esperado de una distribución espacial aleatoria.

El análisis de regresión logística mostró resultados contrastantes para los casos de cinco o más años de monocultivo de soja y cinco o más años de rotación recomendada (Cuadro 2.4). Se encontraron coeficientes negativos y significativos para las variables tamaño de unidad catastral y Capacidad de Uso para explicar la ocurrencia de monocultivo de soja; mientras que se observaron coeficientes positivos y significativos para ambas variables para explicar la presencia de rotación recomendada. Elevación mostró una relación significativa y positiva solamente en casos de monocultivo de soja.

Cuadro 2.4. Coeficientes de Regresión Logística para explicar la ocupación de sitios con cinco o más años de monocultivo de soja y con cinco o más años de rotación recomendada.

Variable	Monocultivo de soja	Rotación recomendada
Tamaño de unidad catastral	-0,60235*	0,08063*
Capacidad de Uso del suelo	-0,07007*	0,12179*
Elevación	0,24674*	0,01878

* significancia al 0,05.

2.4. Discusión

Se generaron siete mapas de cultivos, correspondientes a siete campañas agrícolas consecutivas con una exactitud general superior al 85 %, ubicándose en un rango similar a la obtenida en otros trabajos de clasificación de cultivos (Deschamps et al. 2012; Waldner et al. 2015; Kussul et al. 2017). En concordancia con un mayor número de muestras y una mayor disponibilidad de imágenes satelitales, la exactitud fue más alta durante las últimas campañas. La inclusión de maíz tardío como nueva clase, también podría explicar el incremento en exactitud, ya que se observó así una menor confusión entre maíz y soja. La presencia de un bajo número de muestras de algunas clases en algunos períodos como el caso de maíz tardío durante la campaña 2016/2017, estuvo asociada a valores bajos de exactitud de productor y *G-mean*. Waldner et al. (2019) también menciona el posible efecto de reducción de la exactitud en clases con baja representación.

Los cambios observados en el área de cultivos guardaron relación con lo descrito en los reportes de estadísticas nacionales de Argentina (MINAGRI 2017), con incrementos en el área de soja durante las primeras campañas y una reducción

generalizada en el área sembrada con trigo. La asociación observada entre el área de soja de primera y los precios internacionales de *commodities* permite suponer una gran volatilidad en la decisión de siembra, o que son frecuentes ajustes en la planificación de una secuencia de cultivos a largo plazo. Durante el período de estudio, las tasas de exportación (retenciones) y las restricciones a la exportación cambiaron a fines de 2015, reduciéndose las tasas de exportación para el maíz, junto a la eliminación de restricciones para la exportación de trigo (Bouët y Laborde Debucquet 2016). La fuerte reducción en el área de soja de primera y el incremento en el área de maíz y trigo durante la última campaña (2016/2017) pudieron haber estado asociadas también a este proceso.

La resolución espacial y la continuidad temporal de los mapas generados permitieron caracterizar secuencias de cultivo a nivel de lote. Esto es un gran aporte de información en relación a la disponible previamente en la región para describir estos procesos, que estaba basada en fuentes de mucha menor resolución espacial como las estadísticas oficiales de área sembrada a nivel de departamento (e.g. MINAGRI 2017), o secuencias de cultivos registradas en sitios puntuales (Martini y Angeli 2017). Esto permite la cuantificación de la ocurrencia de secuencias de cultivos, un análisis espacial de las mismas y su vinculación con otra información espacialmente explícita para identificar posibles causas de distribución de los casos e impactos en la producción y el funcionamiento de sistemas agrícolas.

La información espacialmente explícita de tipos de cultivos permitió describir que las prácticas de manejo más frecuentes en esta área implicaron la alternancia de períodos consecutivos de siembra de soja de primera (cultivo con importante flujo de capital) con períodos de rotación (opción de conservación). Es así que más de la mitad del área mostró al menos dos años consecutivos de soja de primera, pero también mostró dos

años o más de rotación recomendada, reflejando la escasez de planificaciones rígidas a largo plazo. Desviaciones sobre un plan de rotaciones también fueron mencionadas en otros lugares que cuentan con registros detallados de secuencias de cultivos como en Alemania (Stein y Steinmann 2018), o en las Planicies Centrales de Estados Unidos de América (Plourde et al. 2013) donde observaron variaciones de una rotación entre maíz y soja, a monocultivo de maíz o de soja durante algunos períodos. Es de considerar que en el área de estudio cerca del 5 % del área agrícola presentó monocultivo de soja durante todo el período de estudio. Por otro lado, en una magnitud similar (2,5 %), otros productores agropecuarios siguieron la rotación recomendada durante todo este período de 7 campañas.

Considerando las transiciones entre cultivos a lo largo del tiempo se pudo asociar la reducción en el área de trigo desde 2012/2103 a 2015/2016 a reducciones en la ocurrencia de la secuencia soja de primera / trigo-soja, y a aumentos en las secuencias de soja de primera / soja de primera y trigo-soja / maíz. La reducción del área de soja durante la última campaña estuvo asociada a una fuerte reducción del monocultivo (soja de primera a soja de primera) en ese período. Es así que los cambios mencionados en las condiciones de exportación pudieron ser también un factor que disminuyó la realización de monocultivo.

El agrupamiento de casos de rotación recomendada a mayores distancias que para monocultivo de soja (2000 m vs. 1000 m aprox.) indica que la rotación recomendada ocurre a una escala espacial más grande, por ejemplo a nivel de establecimiento, en lugar de a nivel de lote como podría ser el caso de monocultivo de soja. Esto sugiere que la implementación de un plan de rotación ocurriría a nivel de establecimiento y no a nivel de lote.

Los casos de rotación recomendada fueron más frecuentes en unidades catastrales de mayor tamaño, probablemente asociado a productores más capitalizados (Rada et al. 2019). Esto implicaría una menor necesidad de flujo de fondos a corto plazo y mayores posibilidades de planificación a largo plazo. Por el contrario, la asociación negativa entre monocultivo de soja y el tamaño de la unidad catastral, además de poder estar asociada a una necesidad de fondos a corto plazo, podría reflejar peores condiciones de negociación de arrendamientos en productores menos capitalizados, que puede derivar en arrendamientos a corto plazo o sin restricciones (Pengue 2005; Haro Sly 2017). Bert et al. (2011) también menciona relaciones entre tenencia de la tierra y grado de rotación, en que propietarios que manejan la tierra son más propensos a realizar rotaciones que requieren una planificación a largo plazo, mientras que arrendatarios buscan maximizar la rentabilidad a corto plazo. En otras regiones (Estados Unidos de América), también se identificó una asociación positiva (a través de regresión logística) entre tamaño de establecimiento y adopción de prácticas conservacionistas, así como una relación negativa entre la implementación de prácticas de mediano plazo y casos de arrendamiento (Soule et al. 2000).

El monocultivo de soja fue más frecuente también en suelos de mejor calidad (bajo valor de capacidad de uso o ubicados en posiciones del relieve más elevadas), sugiriendo que largos períodos de monocultivo pueden ser insustentables económicamente en suelos de baja calidad. Reducciones en las propiedades físicas del suelo asociadas al monocultivo de soja (Novelli et al. 2011; Zuber et al. 2015; Nouwakpo et al. 2018; Novelli et al. 2020), podrían hacer que en suelos de peor calidad sometidos a monocultivo de soja, se llegue antes a disminuciones de rendimiento que no permitan una rentabilidad adecuada..

2.5. Conclusiones

La generación de información continua y detallada a lo largo de siete campañas agrícolas consecutivas generó un aporte importante al conocimiento de la distribución espacial de cultivos y secuencias de cultivos, que permitió realizar cuantificaciones objetivas del grado de monocultivo y rotación en el área de estudio y analizar su distribución espacial en relación a una serie de variables. Los resultados también permitirían cuantificar el impacto de las rotaciones en el rendimiento (Martini y Angeli 2017), y en el funcionamiento de sistemas agrícolas (Glavan et al. 2015; Kroes et al. 2019) en la medida que exista información a esta escala.

La ocurrencia de casos de monocultivo de soja y de rotación recomendada estuvo relacionada con el tamaño de parcela catastral. Si se tiene en cuenta que el tamaño de parcela catastral guarda relación con el grado de capitalización de un productor (Rada et al. 2019), que a su vez esto influye en la decisión de arrendar la tierra (Pengue 2005; Haro Sly 2017), o modifica la capacidad de negociación de contratos de arrendamiento (Alberletche et al. 2010), y esta condición afecta la planificación de secuencias de cultivo (Soule et al. 2000; Bert et al. 2011), se puede aceptar la hipótesis de que la dominancia de una especie en la rotación, como sería el caso de monocultivo de soja, está controlada por factores humanos, como la condición de arrendamiento, identificada a partir del tamaño de parcela catastral. La gran relación observada entre el área sembrada de soja y el precio internacional permite inferir que el margen bruto o el resultado económico del cultivo influyen también en la decisión de la secuencia de cultivos.

Los índices que describen las secuencias de cultivos utilizadas en este capítulo no permitieron relacionar a la riqueza de especies con las variables analizadas, dado que

solo se analizaron espacialmente los casos de monocultivo de soja y rotación recomendada. Se concluye entonces que la información generada no permite aceptar o rechazar la hipótesis de que la riqueza de especies está controlada por variables biofísicas. Sería necesario considerar una mayor cantidad de indicadores de secuencias de cultivos para poder concluir sobre esta hipótesis.

Capítulo III

Caracterización del crecimiento de soja a partir de RADAR de Apertura Sintética (SAR) y sensores ópticos

3.1. Introducción

En Argentina, el principal cultivo extensivo es la soja, cubriendo una superficie de 16 Mha en el año 2020 (MINAGRI 2021). Durante la última década, el país estuvo entre los tres principales productores y exportadores de soja a nivel mundial (FAOSTAT 2021). Gran parte de las estimaciones actuales de rendimiento y producción en el país se han realizado a una escala gruesa (e.g. departamento o región), en muchos casos a partir de fuentes subjetivas como la provista por informantes calificados (SAGyP 2023; Bolsa de Cereales de Buenos Aires 2023). La generación de herramientas que permitan caracterizar el crecimiento y rendimiento de cultivos de soja a nivel de lote y con una extensión regional o nacional permitirá avanzar en dos aspectos: 1) mejorar las predicciones de rendimiento y producción del principal cultivo del país y 2) caracterizar el rendimiento pasado a escala detallada, evaluar su distribución espacial y cambios temporales y su relación con diversas variables ambientales y de manejo.

Los sensores remotos, además de permitir la caracterización del uso y cobertura del suelo, son utilizados para el seguimiento del estado y desarrollo de cultivos. De esta manera, es posible generar información de la historia de uso del suelo y del crecimiento y rendimiento de cultivos a una misma escala de análisis y evaluar la relación entre ambas capas de información. Es frecuente el uso de imágenes ópticas para estimar variables que describen la tasa de crecimiento de cultivos como el índice de área foliar (Myneni et al. 1994; Dong et al. 2020), la fracción de radiación interceptada (Daughtry et al. 1992; Myneni et al. 1994; Myneni et al. 2002; de Abelleira y Verón 2014; Gitelson et al. 2014; Gitelson 2019), o la cobertura de vegetación fotosintética (de la Casa et al. 2018). La absorción de luz roja por pigmentos de la clorofila y la reflexión de la radiación infrarroja por las hojas (Gates 1980) provee las bases físicas por la que

los radiómetros de observación terrestre proveen información útil para caracterizar el estado fisiológico instantáneo de cultivos. La integración de este tipo de información a lo largo del ciclo de un cultivo permitirá estimar la biomasa producida y el rendimiento.

Los sensores ópticos también han sido utilizados para estimar directamente la biomasa o el rendimiento de cultivos (Lobell et al. 2013; Kross et al. 2015; Hosseini et al. 2019). Estas variables estructurales son difíciles de estimar con sensores ópticos, dado que se observan efectos de saturación en los índices espectrales cuando hay elevados niveles de biomasa (Hosseini et al. 2019). La observación de aspectos superficiales de la vegetación (e.g. la presencia de pigmentos en hojas) en algunos momentos, puede no ser representativo de las condiciones que ha sufrido un cultivo a lo largo del período de crecimiento, en que se definen la biomasa total y el rendimiento de un cultivo. Una limitación adicional de las imágenes satelitales ópticas es la imposibilidad de obtener imágenes en presencia de nubes, algo que puede ocurrir en períodos críticos y no permite obtener información. Aumentos en la frecuencia de adquisición de imágenes libres de nubes podrían lograrse utilizando mayor cantidad de plataformas (e.g. Uso de Landsat y Sentinel 2 en conjunto), o con el uso de plataformas con corto tiempo de revisita, generalmente asociadas a un mayor ancho de barrido y menor resolución espacial (e.g. Plataforma MODIS).

Los RADARes de Apertura Sintética (SAR) representan una alternativa promisorio a los sensores ópticos por las siguientes razones: i) al operar en el rango de las microondas, son más sensibles a características dieléctricas (contenido de humedad) y geométricas de la vegetación (tamaño, forma y orientación de los componentes de un canopeo – Mc Nairn et al. 2009); ii) el tipo de dispersión que puede ocurrir en sistemas SAR es dominado por un componente difuso que permite obtener información de un volumen, como el formado por hojas, tallos y el agua contenida dentro de ellos (Attema

y Ulaby 1978), en lugar de obtener información solamente de aspectos superficiales como ocurre en sistemas ópticos (con dominancia del componente superficial de dispersión); iii) la calidad de las imágenes prácticamente no es afectada por la presencia de nubes (Hosseini et al. 2019), asegurando la disponibilidad de imágenes en períodos críticos para el seguimiento de cultivos. Algunas desventajas de los sistemas SAR incluyen: i) la mayor parte de los satélites operan con una única longitud de onda (e.g. banda X, C o L), aunque pueden disponer de múltiples polarizaciones en cada longitud de onda; ii) efectos de saturación, que también pueden ser observados en sistemas SAR dependiendo de la especie, el estado fenológico, el nivel de crecimiento, la configuración espacial y condiciones del suelo (Li y Wang 2018). La integración de imágenes ópticas y de RADAR ha sido sugerido como una alternativa para el monitoreo operativo de sistemas agrícolas (Mc Nairn et al. 2009).

Si bien algunos estudios han descrito variables de crecimiento de cultivos a partir de información SAR (e.g. Hosseini et al. 2019; Reisi-Gahrouei et al. 2019); estos han sido mucho menos frecuentes que los que utilizan información de sensores ópticos. Existe la necesidad de explorar la habilidad para estimar el crecimiento de cultivos a partir de información SAR, considerando los diferentes factores que afectan la retrodispersión (tamaño de plantas, configuración del canopeo, sistema de cultivo, contenido de agua en el suelo y la vegetación) y evaluar en qué medida diferentes longitudes de onda de RADAR y polarizaciones son más útiles para caracterizar el crecimiento de cultivos a lo largo de su ciclo de crecimiento. Se han documentado mayores efectos de atenuación por parte de canopeos densos con estructura orientada preponderantemente en forma vertical (e.g. cereales de invierno) en longitudes de onda cortas que en las largas (Moran et al. 2012; Acuña et al. 2019). Por el contrario,

mayores longitudes de onda (e.g. banda L) han mostrado la habilidad de identificar cultivos de gran porte como el maíz (Mc Nairn et al. 2009).

En Argentina, los cultivos de grano se siembran mayoritariamente en siembra directa (Satorre 2011), presentando el suelo valores bajos y estables de rugosidad en comparación con sistemas de labranza convencional (Beale et al. 2019). La rugosidad del suelo es uno de los factores más relevantes que afectan la retrodispersión SAR (Ulaby et al. 1996), lo que hace que la caracterización de cultivos con sistemas SAR pueda ser una herramienta particularmente viable en Argentina, al ser minimizado este efecto con la siembra directa. La longitud de onda de RADAR utilizada definirá la respuesta de diferentes tipos de cultivos. Es así que longitudes de onda menores (e.g. bandas X o C) mostraron mayor respuesta en cultivos de porte pequeño mientras que longitudes de onda mayores como banda L mostraron mayor respuesta en cultivos de gran tamaño (Ferrazzoli et al. 1997; Li et al. 2019). Similarmente se espera que según el momento del cultivo la respuesta del RADAR sea diferente según la frecuencia utilizada.

Dada la importancia del cultivo de soja en la Argentina, y la disponibilidad de información de mediciones a campo generada a través del sitio San Antonio de Areco en la Pampa Ondulada (JECAM 2023), y la alta densidad de imágenes ópticas y de RADAR obtenidas, se avanzó en la caracterización de variables de crecimiento de este cultivo a partir de información satelital. La biomasa es uno de los determinantes finales del rendimiento. La relación entre ambas variables está dada por el índice de cosecha (fracción de la biomasa total que se cosecha como grano), un valor que presenta gran estabilidad, en particular para cultivos de soja (Vega et al. 2000).

Los objetivos de este capítulo fueron:

- 1) Evaluar la habilidad de diferentes plataformas SAR y ópticas para caracterizar variables de crecimiento en soja a lo largo de su ciclo de crecimiento.
- 2) Generar un modelo de estimación de biomasa seca en soja mediante la integración de información de sistemas SAR y ópticos.

3.2. Materiales y Métodos

3.2.1. Área de estudio

Los sitios de estudio (campos de producción comercial) se encuentran incluidos dentro del área definida en el capítulo anterior (sección 2.2.1) en la Pampa Ondulada, siendo también parte del sitio de validación JECAM San Antonio de Areco (JECAM 2023). En este capítulo en particular, los lotes de producción se encuentran dentro del partido de San Antonio de Areco en la provincia de Buenos Aires (Latitud: 34,1963° S; Longitud: 59,5765° O). Se utilizaron mediciones e imágenes adquiridas durante la campaña 2011/2012 para generar diferentes modelos predictivos de variables de crecimiento de cultivos de soja. Para realizar una validación se utilizaron mediciones e imágenes adquiridas durante la campaña 2010/2011.

3.2.2. Imágenes satelitales

Durante la campaña 2011/2012 se obtuvieron imágenes de cuatro plataformas satelitales (Figura 3.1): dos sistemas SAR de alta resolución de diferentes frecuencias, RADARSAT 2 (RS-2) en banda C (resolución: 8 m) y TerraSAR-X (TSX) en banda X (resolución: 6,6 m); y dos sistemas ópticos con diferente resolución espacial, MODIS (resolución: 250 m) y Landsat 7 ETM (resolución: 30 m).

Las imágenes SAR fueron solicitadas especialmente para ser adquiridas en modos de polarización completa (HH: emisión horizontal y recepción horizontal; HV: emisión horizontal y recepción vertical; VH: emisión vertical y recepción horizontal y VV: emisión vertical y recepción vertical) para el caso de RS-2 (Fine Quad Pol), y polarización dual (con polarizaciones HH y VV) para TSX. Se solicitó también un ángulo de observación fijo para todas las escenas de una misma plataforma: $40,91^\circ$ (RS-2 - modo FQ21) y $31,58^\circ$ (TSX - modo stripFar_007R) para evitar efectos del ángulo de incidencia sobre la retrodispersión SAR entre fechas de adquisición. Las imágenes fueron calibradas para obtener el coeficiente de retrodispersión (σ^0) en decibeles (dB) y ortorectificadas con apoyo de un modelo digital de elevación del SRTM (Farr et al. 2007). El procesamiento se realizó con el software SNAP (ESA 2023). Finalmente se ajustó la georeferenciación manualmente a partir de puntos de referencia disponibles.

También se utilizaron imágenes Landsat 7 de reflectancia superficial (Colección 1, Tier 1) obtenidas y procesadas dentro de la plataforma *Google Earth Engine* (Gorelick et al. 2017) donde se realizó un filtrado por nubes y la generación de índices. Las imágenes MODIS correspondieron al producto MOD13Q1 de la colección 6 y fueron descargadas del repositorio LPDAAC de la NASA (Didan 2015). Estas fueron procesadas localmente para mantener su proyección original sinusoidal. Para ambas plataformas se utilizaron los valores de reflectancia superficial en rojo e infrarrojo (IR), así como también el Índice de Vegetación Normalizado (IVN) derivado de ellas. Solamente las imágenes satelitales obtenidas con una diferencia menor a 6 días con respecto a las fechas de las mediciones a campo fueron consideradas para el análisis (Figura 3.1).

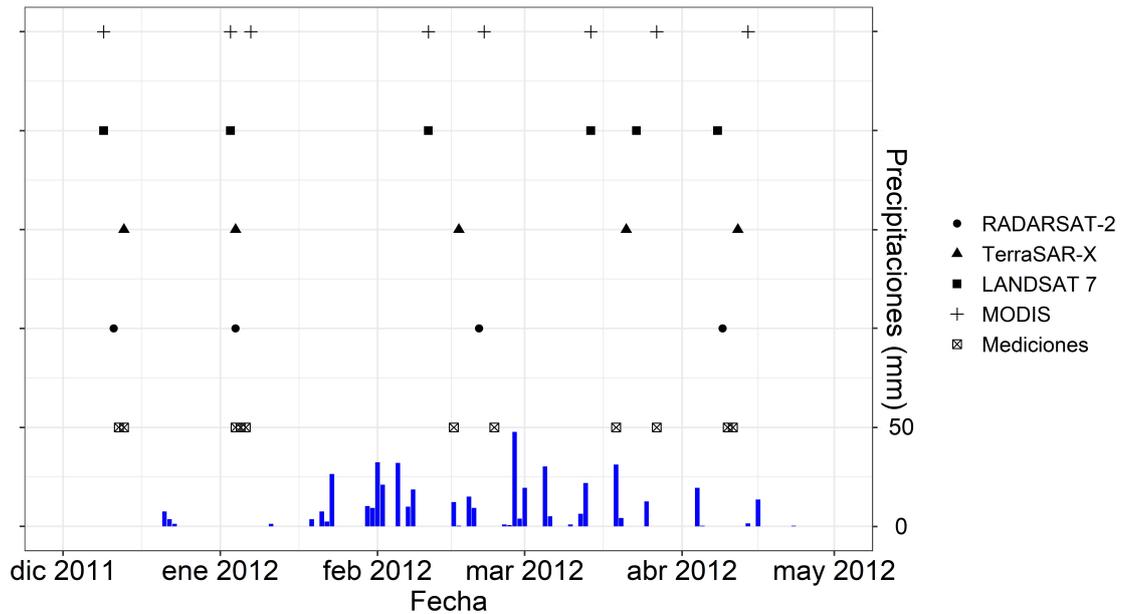


Figura 3.1. Fecha de mediciones realizadas a campo y de adquisiciones de imágenes de las plataformas RADARSAT 2, TerraSAR-X, Landsat y MODIS. El eje secundario muestra los valores de precipitación a lo largo de la campaña 2011/2012 (barras azules).

3.2.3. Mediciones a campo

Para la evaluación de variables de crecimiento y generación de modelos se establecieron cinco sitios de muestreo sobre cada uno de diez lotes cultivados con soja de primera y de segunda a lo largo de la campaña agrícola 2011/2012. La configuración espacial de las mediciones fue establecida para permitir la inclusión de uno o dos sitios de muestreo sobre píxeles MODIS puros en su proyección sinusoidal (250 m de lado - Figura 3.2). De esta manera, cada uno de los 10 lotes dispuso de tres píxeles MODIS puros (i.e. píxeles contenidos completamente dentro de los lotes). Para la validación de modelos se utilizaron mediciones realizadas sobre siete lotes de cultivo de soja durante la campaña 2010/2011 ubicados también dentro del partido de San Antonio de Areco. También en este caso se establecieron cinco sitios de muestreo por lote, pero sin considerar la ubicación de píxeles puros MODIS.

En cada una de los cinco sitios de muestreo ubicados dentro de los lotes se midieron las siguientes variables, al menos durante cuatro momentos a lo largo del ciclo del cultivo en cada lote - Figura 3.1):

- Biomasa fresca: Se tomaron dos muestras de biomasa aérea cosechando las plantas presentes en líneas de siembra de 50 cm de largo. El material se mantuvo en bolsas de plástico dobles y fue pesado el mismo día de su cosecha con balanza digital con precisión de 0.01 g.
- Biomasa seca: las mismas muestras utilizadas para biomasa fresca fueron secadas en estufa durante 72 horas o hasta obtener un peso constante. Las muestras fueron pesadas con balanza digital con precisión de 0.01 g.
- Fracción de radiación fotosintéticamente activa interceptada (FAPAR): En cada unidad de muestro se tomaron cuatro muestras de radiación fotosintéticamente activa mediante un ceptómetro (Cavadevices, Buenos Aires, Argentina). Las mismas se realizaron en 6 posiciones: dos encima del canopeo (una medición hacia arriba y una hacia abajo), y cuatro debajo del canopeo (dos hacia arriba y dos hacia abajo perpendiculares entre sí) realizadas a 45° de la línea de siembra.
- Altura de plantas: Se obtuvieron 5 registros por sitio de muestreo midiendo la parte más alta de 5 plantas seleccionadas al azar.
- Contenido de humedad del suelo: En cada sitio se determinó la humedad gravimétrica del suelo tomando dos muestras de suelo de los primeros 5 cm utilizando un cilindro metálico. Se obtuvo una muestra sobre la línea de siembra y otra muestra del espacio entre líneas. Las muestras fueron guardadas en bolsa de plástico doble, pesadas en el día y luego secadas en estufa hasta peso constante. Las muestras fueron pesadas con balanza digital con precisión de 0.01 g.



Figura 3.2. Ejemplo de la configuración espacial de las mediciones a campo. Puntos rojos: sitios de muestreo; polígonos blancos: contorno de píxel de la plataforma MODIS en proyección sinusoidal; polígonos amarillos: borde de lote de cultivo.

3.2.4. Análisis de datos y modelado

Para analizar la información obtenida durante la campaña 2011/2012 se establecieron tres unidades de análisis en cada lote que se corresponden con el área de cada píxel puro MODIS en proyección sinusoidal (Figura 3.2). Es así que se promedió la información registrada (tanto desde imágenes satelitales como de mediciones a campo) en cada uno de estos sectores. Esto permite comparar sobre cada una de estas áreas la información medida con la información obtenida de cada una de las plataformas, siendo MODIS la de menor resolución espacial. Para la validación que se

realizó con información de la campaña 2010/2011, al no contar con píxeles puros dentro de todos los lotes, se consideró como unidad de análisis al área correspondiente cada lote de cultivo, excluyendo un *buffer* interior de 30 metros.

Se realizaron los siguientes análisis:

- 1) Ajuste de todas las variables medidas con las capas de información satelital obtenidos durante todo el ciclo de crecimiento 2011/2012. Para cada variable se seleccionó el mejor modelo, entre lineal y logarítmico, utilizando el criterio de Akaike.
- 2) Ajuste de todas las variables biomasa húmeda y seca con las capas de información satelital obtenidos durante diferentes períodos del ciclo de crecimiento 2011/2012. Se identificaron dos períodos a partir de la determinación del momento en que se observó el máximo valor del IVN de cada unidad de análisis, por lo que se ajustaron separadamente modelos con la información previa al momento del máximo IVN y posterior al momento de máximo IVN. Para cada variable se seleccionó el mejor modelo, entre lineal y logarítmico, utilizando el criterio de Akaike.
- 3) Desarrollo de un modelo integrando información SAR y óptica para estimar biomasa seca, la variable más asociada al rendimiento.
- 4) Validación del modelo que integra información SAR y óptica a partir de mediciones obtenidas durante la campaña 2010/2011, utilizando las plataformas RS-2 y Landsat 7 ETM. Se calculó el coeficiente de determinación y la raíz del cuadrado medio del error (RMSE) entre los datos estimados y medidos.

3.3. Resultados

3.3.1. Análisis considerando el ciclo de crecimiento completo

Considerando todo el período de crecimiento analizado, las variables medidas que mejor ajuste mostraron con las capas e índices satelitales fueron biomasa fresca y FAPAR (r^2 promedio: 0,67), seguido por altura de plantas (r^2 promedio: 0,59) y biomasa seca (r^2 promedio: 0,52) (Cuadro 3.1 –Figuras Apéndice A.3.1 a A.3.4). En general los coeficientes de determinación más altos fueron observados con RS-2 en polarización HV y reflectancia en rojo de sensores ópticos. Comparando los sensores SAR, RS-2 mostró mayor coeficiente de determinación que TSX para las variables que describen la vegetación, mientras ambas plataformas mostraron un bajo ajuste para humedad del suelo (r^2 promedio: 0,09). Comparando las polarizaciones utilizadas, RS-2 (con polarización completa) mostró mayor coeficiente de determinación en promedio para HV (0,64) que para HH y VV (0,58); mientras que TSX (con polarización dual solamente), mostró mayor correlación para VV (0,41) que para HH (0,37).

Los dos sensores ópticos considerados mostraron similar respuesta a las variables medidas, con la excepción de la reflectancia en IR donde mostraron algunas diferencias, teniendo MODIS menor ajuste (Cuadro 3.1). En promedio, ambos sensores mostraron el mayor coeficiente de determinación en la reflectancia en rojo (0,68 con Landsat y 0,69 con MODIS), seguido por el IVN (0,61 con Landsat y 0,56 con MODIS); mientras que IR mostró en general bajo coeficiente de determinación (0,31 con Landsat y 0,15 con MODIS).

FAPAR fue mejor modelada con modelos lineales con excepción de RS-2 que se ajustó mejor con un modelo logarítmico (Tabla 3.1). Esta variable mostró un coeficiente de determinación particularmente alto con RS-2 HV y reflectancia en rojo e IVN. La

mayor parte de los modelos para biomasa fresca fueron logarítmicos con excepción de IR que mostró mejor ajuste con modelo lineal. La mayor correlación para biomasa fresca fue observada también con RS-2 HV y con reflectancia en rojo de Landsat y MODIS. Biomasa seca mostró menor coeficiente de determinación que biomasa fresca para todas las capas de información SAR y ópticas, y en todos los casos ajustó mejor con un modelo logarítmico.

Cuadro 3.1. Coeficientes de determinación de los modelos ajustados para las variables medidas en cultivos de soja y suelo a lo largo de todo el período de medición. Se identifica el mejor modelo (lin: lineal, o log: logarítmico) según el criterio de Akaike.

Sensor	Capa	Biomasa seca		Biomasa fresca		FAPAR		Altura		Humedad suelo	
		r ²	Modelo								
RS-2	HH	0,73	log	0,8	log	0,67	log	0,68	log	0,03	lin
	HV	0,72	log	0,83	log	0,82	log	0,69	log	0,13	lin
	VV	0,73	log	0,81	log	0,67	log	0,68	log	0,03	lin
TSX	HH	0,3	log	0,45	log	0,59	Lin	0,35	log	0,19	log
	VV	0,35	log	0,51	log	0,62	Lin	0,4	log	0,18	log
Landsat	Rojo	0,76	log	0,87	log	0,86	Lin	0,85	log	0,06	log
	IR	0,22	log	0,48	Lin	0,44	Lin	0,37	lin	0,02	log
	IVN	0,63	log	0,78	log	0,85	Lin	0,76	log	0,01	lin
MODIS	Rojo	0,7	log	0,83	log	0,87	Lin	0,84	log	0,2	lin
	IR	0,09	log	0,27	Lin	0,23	Lin	0,15	lin	0,03	lin
	IVN	0,54	log	0,7	log	0,8	Lin	0,7	log	0,09	lin

La observación en detalle de la relación entre la retrodispersión en RS-HV y biomasa fresca y seca, muestra diferencias en los valores de retrodispersión según el

contenido de humedad vegetal (en porcentaje) en el momento de la medición (Figura 3.3). Es así que un grupo de puntos con valores similares de biomasa seca, pero de menor contenido de humedad (puntos oscuros) mostraron valores de retrodispersión mucho menores que puntos con mayor contenido de humedad (puntos claros). Por el contrario, en el modelo de biomasa fresca, los puntos fueron agrupados a lo largo de un mismo patrón de distribución, ya que puntos con bajo contenido de humedad (en porcentaje) mostraron también valores relativamente bajos de biomasa fresca.

3.3.2. Análisis considerando diferentes períodos a lo largo del ciclo de crecimiento

En esta sección se analizaron los datos obtenidos a partir de mediciones y de información satelital considerando dos sub-períodos: i) previo al momento máximo de IVN y ii) posterior al momento máximo de IVN. En general el ajuste de los modelos fue mejor utilizando los datos previos al momento de máximo de IVN, pero la magnitud de variación entre ambos períodos fue diferente según la variable y la capa de información satelital considerada (Tabla 3.2 - Figuras Anexo A.3.6 a A.3.9). Biomasa seca mostró una gran disminución en los valores de r^2 durante el período posterior al máximo IVN, mientras que para biomasa fresca la reducción en r^2 fue menor. Los sensores ópticos mostraron en general alta correlación con biomasa previo al momento de máximo IVN. Las capas de información SAR volvieron a mostrar mayor correlación para banda C (RS-2) que para banda X (TSX) para las dos variables medidas. Algunas capas de información como RS-2 HV y reflectancia en IR e IVN de Landsat mantuvieron alto coeficiente de determinación para biomasa fresca aún con posterioridad al máximo de IVN.

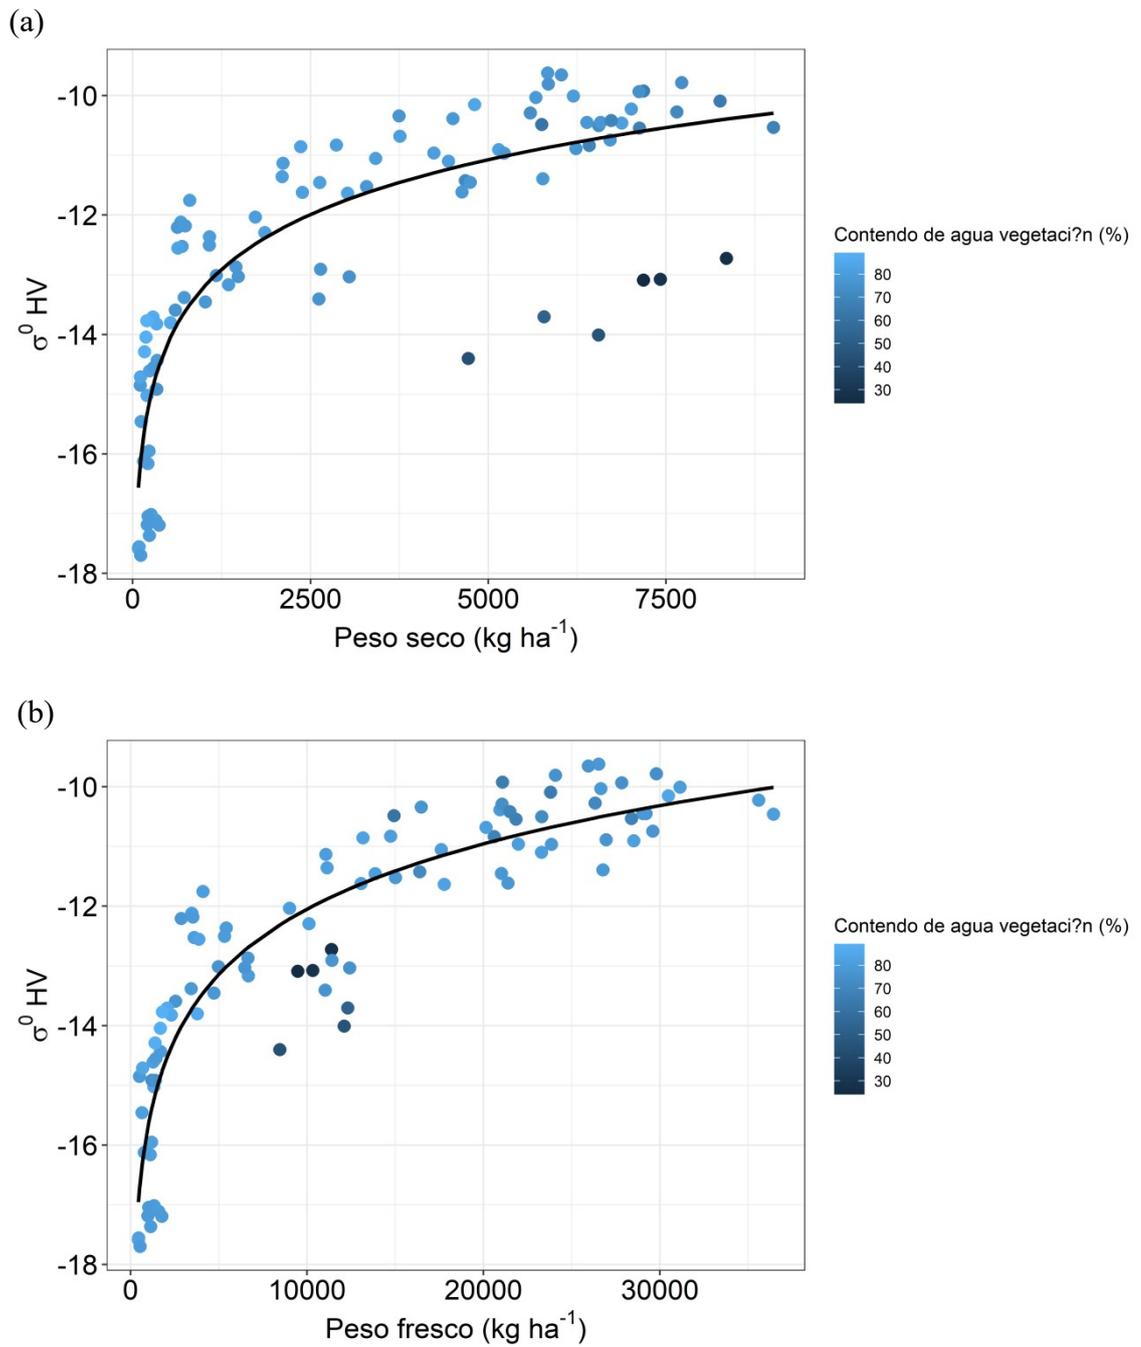


Figura 3.3. Relaci?n entre coeficiente de retrodispersi?n en RADARSAT 2 HV y a) biomasa seca (modelo ajustado: $y=22,353+\log(1,324x)$, r^2 aj.=0,72) y b) biomasa fresca (modelo ajustado: $y=-26,584+\log(1,578x)$, r^2 aj.=0,83).

Cuadro 3.2. Coeficientes de determinación de los modelos ajustados para las variables biomasa seca y fresca en dos sub-períodos: previo y posterior al momento de máximo IVN. Se identifica el mejor modelo (lin: lineal, o log: logarítmico) según el criterio de Akaike.

		Biomasa seca				Biomasa fresca			
		previo a máximo IVN		posterior a máximo IVN		previo a máximo IVN		posterior a máximo IVN	
		r ²	Modelo	r ²	Modelo	r ²	Modelo	r ²	Modelo
RS-2	HH	0,79	log	0,01	log	0,82	Log	0,43	log
	HV	0,76	log	-0,02	lin	0,8	Log	0,67	log
	VV	0,79	log	0,01	log	0,82	log	0,44	log
TSX	HH	0,62	log	0	log	0,68	log	0,3	log
	VV	0,71	log	-0,01	log	0,76	log	0,36	log
Landsat	Rojo	0,87	log	0	lin	0,9	log	0,51	log
	IR	0,8	lin	0,02	lin	0,81	lin	0,59	log
	IVN	0,89	log	0	lin	0,91	log	0,6	log
MODIS	Rojo	0,78	log	0	log	0,85	log	0,37	log
	IR	0,68	lin	-0,01	log	0,66	lin	0,34	log
	IVN	0,88	log	-0,01	log	0,91	log	0,42	log

3.3.3. Desarrollo de un modelo integrando información derivada de información SAR y óptica para estimar biomasa seca en cultivos de soja

Se propuso un modelo que estime en primer lugar la biomasa fresca y que considere la dinámica temporal del contenido de humedad vegetal para estimar finalmente la biomasa seca. Para estimar biomasa fresca se consideró el modelo que utiliza SAR banda C (RS-2) en polarización HV debido a su gran estabilidad a lo largo

de todo el ciclo del cultivo de soja. Para estimar el contenido de humedad vegetal se utilizó información de sensores ópticos.

Se define al contenido de humedad de la vegetación (VM) en un momento determinado a partir de la biomasa seca (DB) y fresca (WB) por medio de la siguiente ecuación:

$$VM = \frac{WB-DB}{WB} \quad (1)$$

Las mediciones sobre cultivos de soja mostraron valores de VM estables y cercanos a 80 % desde el inicio del ciclo de cultivo hasta el mes de marzo, mostrando a partir de ahí una disminución y mayor variabilidad de los valores de VM (Figura 3.4). Se utilizó la información de IVN de MODIS para generar un modelo predictivo de VM , considerando si los datos eran previos o posteriores al momento del máximo IVN (Figura 3.5) en cada unidad de análisis. Se ajustó un modelo cuadrático para estimar contenido de agua de la vegetación para el período posterior al máximo IVN ($VM2$):

$$VM2 = -0,6439 + 3,161e^{-04}IVN - 1,761e^{-08}IVN^2 \quad (2)$$

Para el período previo al máximo IVN, se consideró un valor fijo de VM de 80,3 %, que representa el promedio de los valores medidos de VM durante este período donde se observó una gran estabilidad en el valor de VM (Figura 3.5).

De esta manera, DB es estimada usando dos modelos diferentes:

- 1) Para el momento previo al máximo IVN, se utiliza la ecuación 1, despejando DB a partir de WB considerando un valor de VM de 80,3 %:

$$DB = -(WB \cdot 0.803 - WB) \quad (3)$$

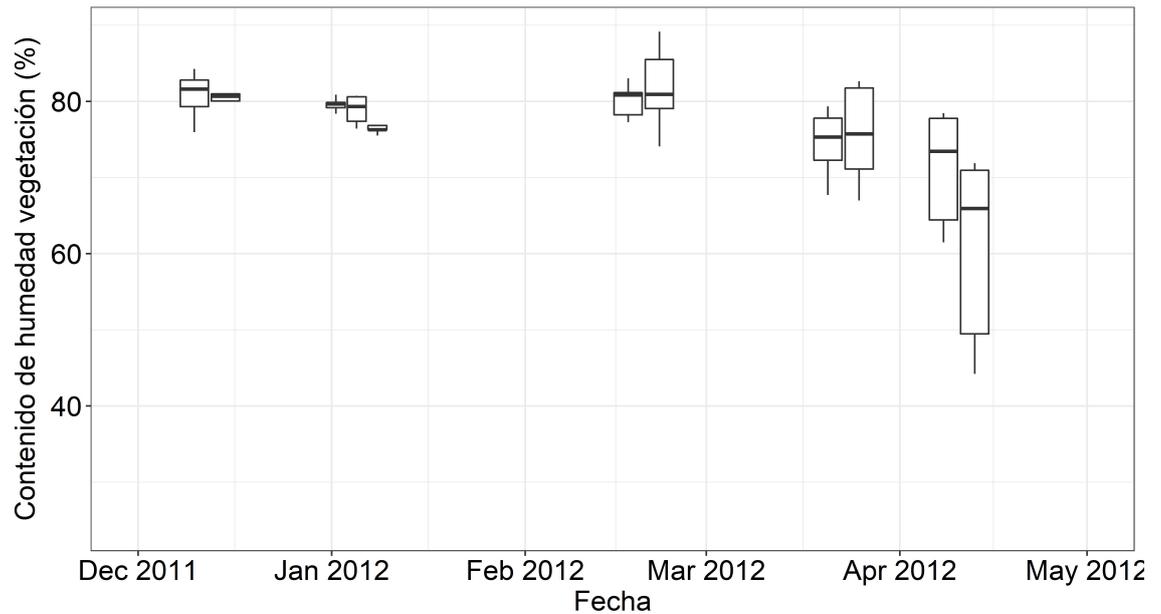


Figura 3.4. Diagramas de caja de mediciones de contenido de humedad de la vegetación a lo largo del ciclo de crecimiento en cultivos de soja durante la campaña 2011/2012.

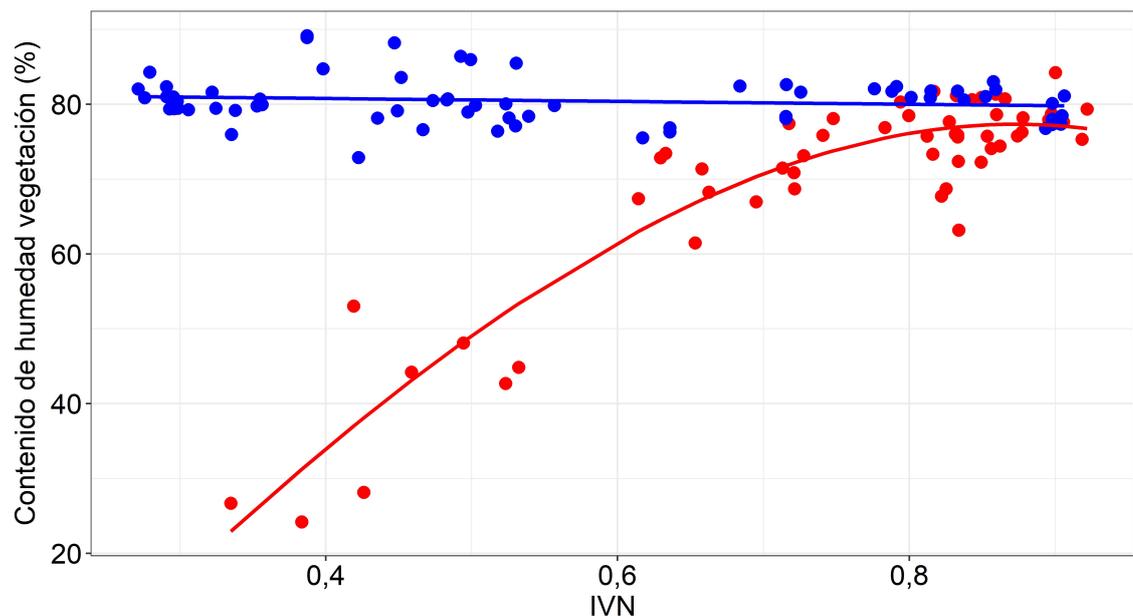


Figura 3.5. Contenido de humedad de la vegetación vs. IVN obtenido de la plataforma MODIS, antes (puntos azules) y después (puntos rojos) del máximo de IVN. Las líneas representan los modelos ajustados para ambos sub-períodos: previo al máximo de IVN (azul; $y=81.5-1.92x$; r^2 aj.=0.04) y después del máximo de IVN (rojo; $y=-64.39+313.1x-176.1x^2$; r^2 aj.=0.85).

2) Para el momento posterior al máximo IVN, DB se estima combinando las ecuaciones 1 y 2:

$$DB = -(WB * (-0,6439 + 3,16e^{-04}IVN - 1,76e^{-08}IVN^2) - WB) \quad (4)$$

A su vez, WB es estimada mediante la inversión del modelo ajustado entre RS-2 HV y los valores medidos (sección 3.3.1):

$$WB = a \log \left(\frac{\sigma_0 HV + 26,5842}{1,5781} \right) \quad (5)$$

3.3.4. Validación

La Figura 3.6 muestra la relación entre los valores medidos de biomasa seca y fresca durante la campaña 2010/2011 y los valores modelados con información SAR únicamente (RS-2 HV – sección 3.3.1) e integrando información SAR y óptica (sección 3.3.3). Para biomasa fresca, utilizando información SAR únicamente se obtuvieron los valores más altos del coeficiente de determinación y más bajos de RMSE relativo (Figura 3.6.c). Para biomasa seca, se observó un mejor ajuste y menor RMSE utilizando el modelo que integra información SAR y óptica (Figura 3.6.b) frente al uso de SAR únicamente (Figura 3.6.a), aunque esta relación mostró cierta subestimación.

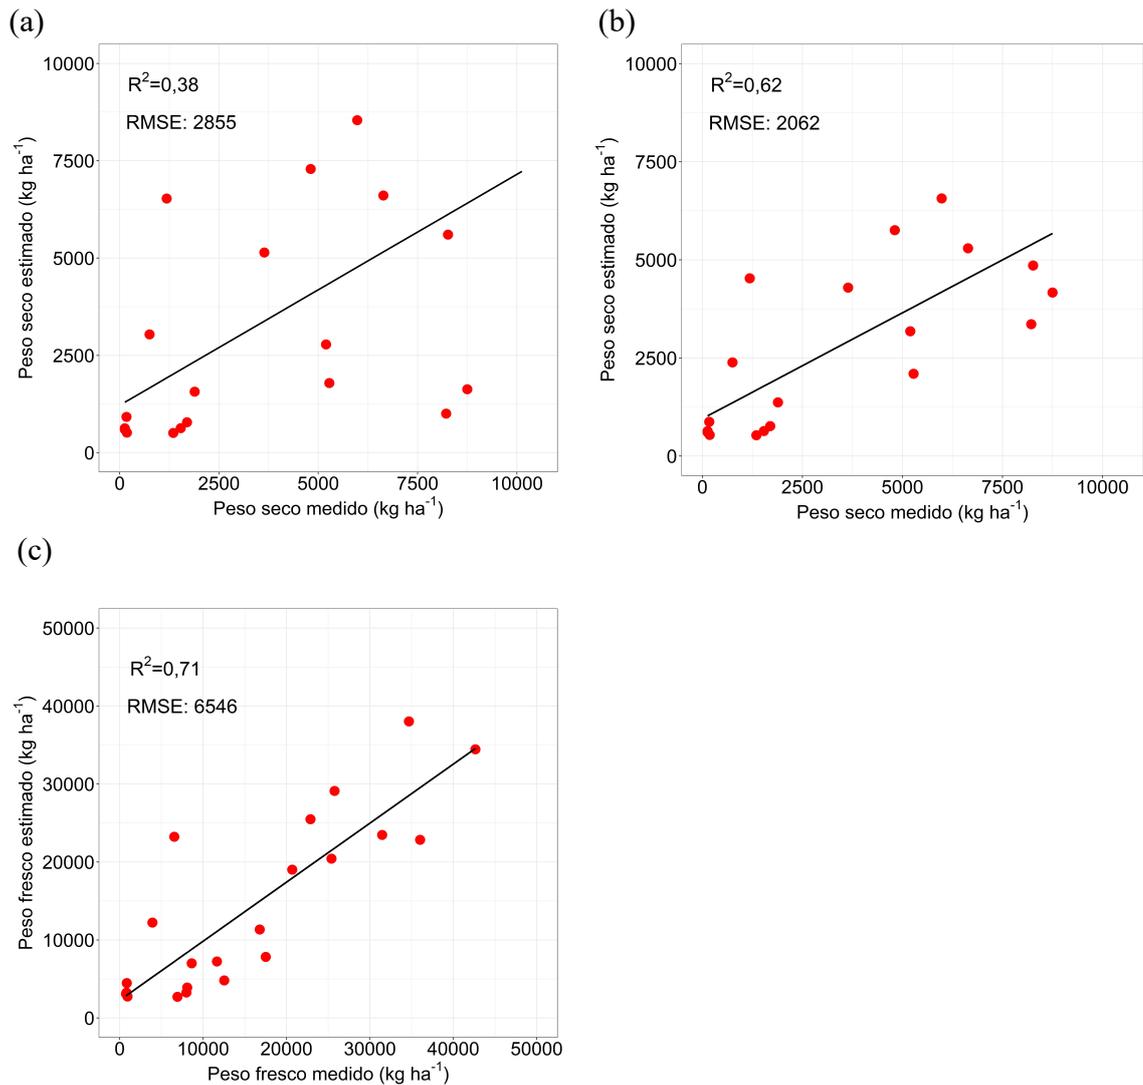


Figura 3.6. Comparación entre valores medidos y estimados de: a) biomasa seca estimada a partir de RADARSAT 2 polarización HV ($y=1219,25+0,5932x$); b) biomasa seca estimada a partir de RADARSAT 2 y Landsat ($y =953,53174+0,53935x$); y c) biomasa fresca estimada con RADARSAT 2 polarización HV ($y =2271,3987+ 0,757x$). La raíz del cuadrado medio del error (RMSE) está en kg ha^{-1} .

3.4. Discusión

En este trabajo se evaluó el uso de diferentes índices y plataformas para estimar variables de crecimiento de cultivos de soja y la humedad del suelo. Es de destacar que se han considerado mediciones realizadas a lo largo de todo un ciclo de cultivos de soja, lo que implica considerar valores de biomasa seca y altura desde muy pequeños al inicio

del ciclo hasta valores cerca de madurez (Figuras Anexo A.3.2 y A.3.4). Otras variables que presentan variación a lo largo del ciclo del cultivo (valores crecientes y luego decrecientes) como FAPAR y biomasa fresca, también fueron medidas en diferentes momentos, y fue considerada esta variabilidad para los análisis realizados (Figuras Anexo A.3.1 y A.3.3). La humedad del suelo también presentó gran variabilidad siguiendo la dinámica del agua con gran influencia de las lluvias y la evapotranspiración durante el período (Figura Anexo A.3.5). Esto representa un aporte adicional de este trabajo, dado que gran parte de los estudios que caracterizan variables biofísicas lo hacen durante períodos cortos donde la relación entre variables es más simple (Gitelson et al. 2014).

Considerando la información de RADAR utilizada, se observó un efecto importante de la longitud de onda. Banda C (RS-2) mostró un mejor desempeño que banda X (TSX) para la caracterización de las variables de crecimiento de soja en los diferentes momentos del ciclo analizados. Es posible que el tamaño alcanzado por los cultivos de soja genere mayores efectos de saturación en una banda más corta como banda X. RS-2 mostró, para todas las variables medidas, el mayor coeficiente de determinación para la polarización HV, un indicador de interacción volumétrica en SAR sobre canopeos vegetales (Sinha et al. 2015; Canisius et al. 2018). TSX, sin polarización HV, mostró mayor correlación para la polarización VV que HH, sugiriendo un efecto de la configuración de líneas de siembra, al menos durante el período inicial del ciclo del cultivo.

Considerando los sensores ópticos, la reflectancia en rojo mostró mayor coeficiente de determinación que la reflectancia en IR e IVN cuando se consideró el ciclo completo del cultivo. IR e IVN mostraron mayor variabilidad al considerar un único momento para todo el período de crecimiento, es decir que la inclusión de datos

del final del período de crecimiento afectó el ajuste para estas capas de información satelital. No ocurrió lo mismo con la reflectancia en rojo que mantuvo un relativamente buen ajuste utilizando un único modelo para todo el período. No se detectaron diferencias importantes entre las plataformas MODIS y Landsat, por lo que plataformas con menor resolución espacial y mayor tiempo de revisita también podrían caracterizar estos sistemas, en la medida que se observen lotes de tamaño considerable.

Se observó un claro efecto del contenido de humedad vegetal en los valores de retrodispersión en banda C. RS-2 mantuvo alto coeficiente de determinación para la estimación de biomasa fresca incluso en la etapa final del ciclo del cultivo, mientras que la biomasa seca presentó muy bajos valores del coeficiente de determinación en esta etapa. Este efecto también se observó en la respuesta diferencial en banda C a casos con diferente contenido de humedad vegetal, pero similares valores de biomasa (Figura 3.3.A, Figura Anexo A.3.9). Otros autores también han mencionado una fuerte respuesta del contenido de agua vegetal a índices derivados de RADAR en soja (Kim et al. 2013).

Los valores medidos de contenido de humedad de la vegetación fueron estables durante un período prolongado del ciclo del cultivo, mostrando una caída en sus valores al final del ciclo. Valores estables en esta variable y similares en magnitud fueron registrados también en otros trabajos como el Experimento de Validación de la Misión Soil Moisture Active Passive (SMAPVEX 12 – Mc Nairn et al. 2014), que mostró valores de 81,3 % en promedio, pero las mediciones solo incluyeron los primeros 60 días del ciclo del cultivo. La fuerte respuesta de la biomasa vegetal a las capas de información SAR, puede entonces utilizarse para estimar la biomasa seca a través de la caracterización adicional del contenido de humedad vegetal a lo largo del ciclo del cultivo.

La estimación de biomasa seca con el modelo propuesto que incluye el uso de información de RADAR y óptica mostró un buen ajuste con datos medidos a campo y valores de RMSE de magnitud similar a otros trabajos que usaron información SAR (Hosseini et al. 2019). También se observó alta variabilidad en las estimaciones para valores elevados de biomasa medidos, lo que puede requerir una calibración adicional para una campaña específica. La identificación de otros mecanismos para caracterizar o modelar el contenido de humedad de la vegetación podría mejorar las estimaciones de biomasa seca en momentos puntuales.

Si bien es esperable una respuesta de la humedad superficial del suelo en sistemas SAR debido a la respuesta a características dieléctricas de los materiales, ésta no fue importante en este estudio en que se analizaron las bandas C y X, a pesar de disponer de un amplio rango de valores de humedad del suelo (Figura Anexo A.3.5). Un comportamiento similar también fue reportado en Canadá cuando se estimó la humedad del suelo en diversos cultivos de grano (Wiseman et al. 2014). Sistemas operativos para la estimación de la humedad del suelo proponen el uso del modelo *Water Cloud* (Bai et al. 2017; Bagdadhi et al. 2017), que caracteriza la doble atenuación de la señal de RADAR por un canopy vegetal para estimar finalmente la humedad del suelo que se encuentra debajo. Siendo tan relevante la respuesta de la vegetación en comparación con la humedad del suelo, surge un cuestionamiento del uso de estas aproximaciones para la estimación de la humedad del suelo, al menos con las longitudes de onda y el tipo de cultivo analizados en este trabajo.

Los modelos generados permitieron caracterizar adecuadamente el peso fresco y seco de soja como predictor de su rendimiento. Los resultados presentados demostraron la capacidad de predecir la biomasa de cultivos a lo largo de todo su ciclo de crecimiento, y no solamente durante los primeros estadios del ciclo, en que en general la

respuesta a variables de crecimiento es más clara y es la etapa que la mayor parte de los estudios abarca (Gitelson et al. 2014).

3.5. Conclusiones

En este capítulo se evaluó el uso de dos sensores SAR (RADARSAT 2 en banda C y TerraSAR-X en banda X) y sensores ópticos (MODIS y Landsat) para estimar variables de crecimiento y humedad del suelo en cultivos de soja a lo largo de diferentes momentos del ciclo de cultivo. Los mejores ajustes a los modelos se obtuvieron con RADAR en banda C y con reflectancia en rojo de los sensores ópticos. En particular, variables como biomasa fresca y FAPAR que tienen una dinámica de incremento y luego disminución mostraron las mayores correlaciones con las capas de información satelital; mientras que variables que se incrementan constantemente (i.e. peso seco) o se incrementan hasta un *plateau* (i.e. altura) mostraron menor correlación. Las variables medidas que describen el crecimiento de la vegetación fueron mucho mejor descriptas que la variable de suelo registrada (humedad del suelo), poniendo en evidencia la dificultad de estimar esta última variable a lo largo del ciclo de crecimiento de cultivos como la soja, al menos con las longitudes de onda utilizadas aquí (bandas C y X en RADAR y rojo e IR en ópticos).

Se generó un modelo que combinó los mejores modelos de estimación de biomasa fresca y el contenido de humedad de la vegetación, para predecir el peso seco a lo largo del ciclo del cultivo. De esta manera se combinó información que proviene de sistemas de naturaleza diferente: SAR para la estimación del peso fresco; y ópticos para describir aspectos asociados a la fenología como inicio de senescencia y contenido de humedad vegetal.

En la medida que se disponga de: i) información de secuencias de cultivos históricas (i.e. mapas de cultivos), e ii) imágenes de RADAR en banda C que cubran un área de interés durante los períodos de crecimiento de los cultivos, se podrá vincular la historia de siembra de diversos lotes con el crecimiento actual de cultivos de soja y así evaluar el impacto de esta práctica a escala regional o nacional.

Capítulo IV

Estimación del impacto de rotaciones en la Pampa Ondulada en el
crecimiento de cultivos y el carbono del suelo

4.1. Introducción

Los sistemas de cultivo modifican en gran medida el ambiente, actuando principalmente sobre aspectos químicos, físicos y biológicos del suelo. Diversos estudios señalan una disminución del contenido total de carbono del suelo asociado al reemplazo de pasturas -o pastizales- por cultivos. El nivel de carbono se estabiliza en valores más bajos que los originales luego de varios años de agricultura continua (Reeves 1997; Andriulo et al. 1999; Ogle et al. 2005). El nivel de carbono en el suelo define en parte su fertilidad al estar fuertemente relacionado con los niveles de nitrógeno del suelo (Campbell 1978). El carbono en el suelo también es un indicador de actividad biológica (Dacunto et al. 2016), facilitando procesos como la agregación de partículas de suelo y el aumento de porosidad.

Otra variable relevante de los suelos agrícolas es su capacidad de retención hídrica. Más allá del contenido total de carbono, la distribución del mismo en los diferentes componentes del suelo puede modificar la proporción de agregados de distinto tamaño. Novelli et al. (2011), observaron disminuciones en la cantidad de macroagregados bajo monocultivo en Molisoles. La distribución de agregados modificará la porosidad del suelo y así su capacidad de infiltración y almacenamiento de agua. Modificaciones en las propiedades del suelo mencionadas podrían afectar el crecimiento y rendimiento de los cultivos.

En particular en la Pampa Ondulada, la variedad de sistemas de cultivos está dada por el maíz, la soja y el trigo y combinaciones entre estas (i.e. cultivo de invierno seguido de cultivo de verano en la misma campaña). La siembra de soja como único cultivo genera una baja disponibilidad de rastrojo en superficie, el que a su vez es rápidamente degradado por su baja relación carbono / nitrógeno (Wright y Hons 2004).

Esto genera también una mayor exposición del suelo durante una gran parte del año, haciéndolo más susceptible a procesos de erosión (Sasal et al. 2017) o de mineralización del carbono del suelo (Lloyd y Taylor 1994; Paustian et al. 2000). El maíz como único cultivo, si bien implica también dejar el suelo sin cultivo durante gran parte del año, permite una menor exposición y un mayor aporte de carbono al sistema debido a su alto volumen de rastrojo con lenta descomposición por su alta relación carbono / nitrógeno. El trigo, presenta una situación intermedia de nivel de rastrojos (volumen intermedio con alta relación carbono / nitrógeno), pero en general está asociado a un cultivo de verano en la misma campaña, lo que implica un menor tiempo de exposición del suelo a factores climáticos adversos y un aporte adicional de carbono del cultivo de verano.

La siembra frecuente de soja como único cultivo en una campaña implicará un riesgo potencial de degradación del suelo. En la medida que se incluyan en la secuencia un cultivo adicional en invierno (trigo), o un cultivo de verano con mayor cantidad de rastrojos, se esperaría lograr una mayor cobertura del suelo durante el año tanto con vegetación viva como con rastrojos y un mayor aporte de carbono al suelo, que derivará en una mejor conservación del ambiente productivo. Es así que la proporción de gramíneas en una rotación se sugiere como un indicador de sustentabilidad en sistemas productivos agrícolas (Martini y Angeli, 2017).

La caracterización del impacto de diferentes secuencias de cultivo se basa generalmente en experimentos a largo plazo que requiere trabajar sobre sitios puntuales (Lund et al. 1993; Sindelar et al. 2015; Barraco et al. 2017). Los efectos de las secuencias de cultivos pueden variar en magnitud y en dirección según las condiciones ambientales particulares del sitio (Reeves 1997; Ogle et al. 2005; Novelli et al. 2017). El uso de sensores remotos, y en particular la utilización de series consecutivas de imágenes satelitales, permite por un lado caracterizar procesos de largo plazo como son

la historia de siembra de cultivos en un lote, y por otro caracterizar procesos de corto o mediano plazo como son la evolución del crecimiento de un cultivo en una campaña agrícola. Una gran ventaja de esta herramienta es que se puede utilizar a escala regional, nacional o global y así considerar el rango de condiciones ambientales y de manejo presentes. La caracterización de secuencias de cultivo en grandes regiones permite a su vez relacionarlas con mediciones puntuales realizadas en un momento específico, brindando una capacidad explicativa adicional a estas mediciones (e.g. mediciones del Observatorio Nacional de Suelos Agropecuarios de Argentina - ONSA 2023). Particularmente, las imágenes de RADAR al operar en el rango de microondas permiten asegurar la obtención de imágenes en forma regular y durante períodos críticos para el crecimiento y desarrollo de los cultivos, aún en presencia de nubes; a diferencia de los sensores ópticos que no permiten la observación de la tierra en días nublados (Mc. Nairn et al. 2009).

El objetivo de este capítulo fue analizar el efecto de diferentes secuencias de cultivo observadas sobre el crecimiento de cultivos medido en biomasa y sobre el carbono orgánico del suelo y proponer posibles mecanismos involucrados. Para ello se utilizó la información de secuencias de cultivos a lo largo de siete campañas agrícolas en un sector de la Pampa Ondulada (obtenida en la sección 2.3.1), y el modelo de crecimiento de cultivos de soja desarrollado en la sección 3.3.3 a partir de imágenes satelitales de RADAR y ópticas, así como también se utilizaron mediciones de carbono del suelo disponibles en el área de estudio.

4.2. Materiales y Métodos

4.2.1. Variables explicativas

Diferentes índices que describen la proporción de algún cultivo en particular o de grupos de especies han sido utilizados en la región para caracterizar secuencias de cultivos (Martini y Angeli 2017; Novelli et al. 2023). También se mencionan índices que describen intensidad de siembra a partir de aproximaciones simples como determinar el número de cultivos por año, o más complejas que caracterizan el tiempo de ocupación de cada cultivo en la secuencia (Novelli et al. 2023). Considerando los cultivos dominantes en Pampa Ondulada y dada la similitud en duración de los cultivos de maíz y soja, el cambio en intensidad de siembra se debería principalmente a la frecuencia del doble cultivo trigo-soja en la secuencia de cultivos.

En esta tesis se generaron cinco índices que describen las secuencias de cultivos observadas durante el período 2010/2017 (siete campañas agrícolas) utilizando la información obtenida en el capítulo II (sección 2.3.1). Los índices utilizados incluyen (Figura 4.1):

- 1) Proporción de soja de primera: cantidad de campañas en las que se identificó soja de primera en relación al total de campañas.
- 2) Proporción de gramíneas en la rotación: cantidad de campañas en las que se identificó maíz o trigo en relación al total de campañas.
- 3) Intensidad de siembra: cantidad de cultivos identificados en relación al número total de campañas (i.e. promedio del número de cultivos por año).
- 4) Número de períodos con rotación recomendada: cantidad de campañas consecutivas en que se observó alguna de las secuencias de una rotación que sigue el siguiente orden:

- a. Primer año: maíz
 - b. Segundo año: soja de primera (cultivo único)
 - c. Tercer año: doble cultivo trigo-soja
- 5) Número de períodos consecutivos con soja de primera: cantidad de campañas consecutivas en que se observó soja de primera.

4.2.2. Variables de respuesta

Como variables de respuesta se consideraron estimaciones de biomasa seca en cultivos de soja generados a partir de los modelos desarrollados en el capítulo III (sección 3.3.3) y mediciones de carbono del suelo realizadas en el área de estudio durante la campaña 2018/2019.

Para la estimación de biomasa seca, se utilizó información disponible de la plataforma RADARSAT 2 (Figura 4.2) e imágenes Landsat y Sentinel 2 obtenidas durante la campaña 2018/2019. Para identificar lotes de soja de primera y de segunda, se utilizó el Mapa Nacional de Cultivos de la campaña 2018/2019 (de Abelleira et al. 2019). Para el análisis de impacto en biomasa a través de imágenes, se consideraron los lotes segmentados en el capítulo II (sección 2.2.3) que presentan un tamaño mayor a tres hectáreas, y que intersectan el área de las escenas RADARSAT 2 disponibles para la campaña 2018/2019 (Figura 4.3). De esta forma se incluyeron 1896 lotes, siendo 1153 lotes de soja de primera y 743 lotes de soja de segunda. Sobre estos lotes se generaron los índices mencionados a partir de las secuencias de siembra y se evaluó la respuesta en biomasa seca, promediando los valores de cada píxel dentro de los lotes. Se consideró un buffer interno de 30 metros para reducir posibles errores de corrección.

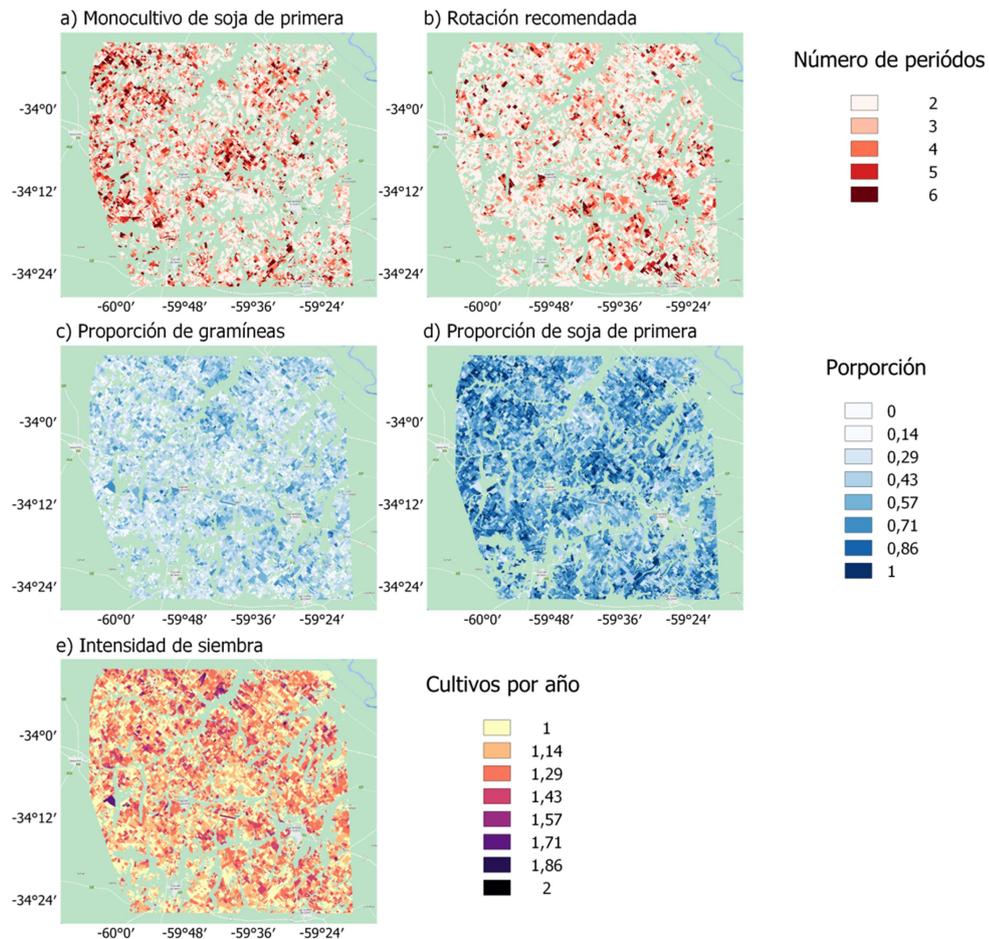


Figura 4.1. Variables de entrada para el análisis del impacto de las rotaciones: a) número de períodos (de 2 años consecutivos) con soja de primera; b) número de períodos (de 2 años consecutivos) con rotación recomendada (maíz / soja de primera / trigo-soja); c) Proporción de gramíneas en la rotación; d) proporción de soja de primera en la rotación; e) intensidad de siembra (número de cultivos por año).

Para evaluar la respuesta en el carbono del suelo, se analizaron los índices derivados de las secuencias de cultivo y su relación con mediciones de carbono del suelo obtenidas en el marco del Observatorio Nacional de Suelos Agropecuarios (ONSA 2023) durante la campaña 2018/2019 (Figura 4.3). Se utilizaron 19 muestras de suelo de los primeros 20 cm obtenidas durante los meses de marzo y abril de 2019. En cada sitio se tomaron entre 4 y 5 sub-muestras obtenidas de un radio máximo de 10 metros desde un punto central georeferenciado. Todo el material recolectado se ubicó

en una bolsa única de entre 0.5 a 1 kg. Las muestras fueron llevadas a laboratorio y se estimó el contenido de carbono (Walkley y Black 1934).

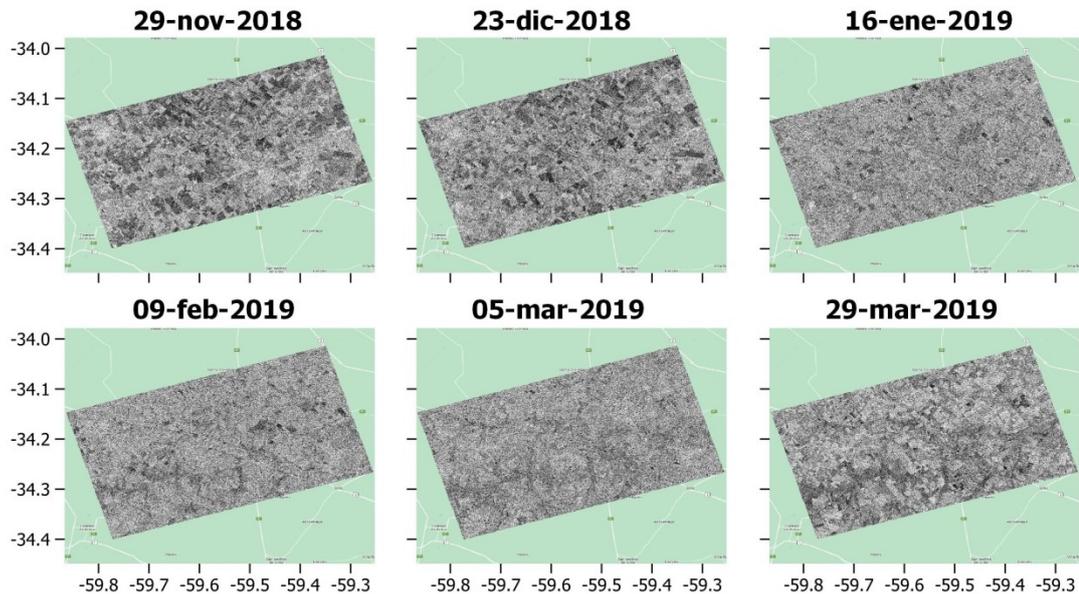


Figura 4.2. Colección de escenas RADARSAT 2 en polarización HV adquiridas en el sitio de estudio durante la campaña 2018/2019.

4.2.2.1. Implementación del modelo de biomasa

La Figura 4.4 describe el proceso de implementación del modelo de biomasa. Se realizó un apilado de capas derivadas de imágenes satelitales y se unificó el tamaño de píxel en 30 m, para poder vincular la información contenida en las diferentes capas. A partir de una colección de escenas RADARSAT 2 en polarización HV, y modo FQ21 (resolución 8 m, ángulo de incidencia $40,91^\circ$) obtenidas para la campaña 2018/2019 (Figura 4.2) se generaron mapas de biomasa fresca de soja a partir del modelo descrito en la sección (3.3.1). Mediante el uso de la plataforma *Google Earth Engine*, y utilizando series de tiempo de la plataforma Sentinel 2 (reflectancia superficial, nivel 2A), se identificó el momento del máximo valor de una curva de IVN de cada píxel. Para estimar el contenido de agua de la vegetación se utilizó el modelo descrito en la

sección 3.3.1, utilizando como variables de entrada el momento de máximo IVN, y los valores de IVN de cada fecha derivado de colecciones de imágenes Sentinel 2 y Landsat 8 (reflectancia superficial, Colección 2, Tier 1), seleccionando las fechas más próximas a cada adquisición de RADARSAT 2 siempre que la diferencia sea menor a 5 días. Previamente se aplicaron los filtros de nubes provistos por cada plataforma.

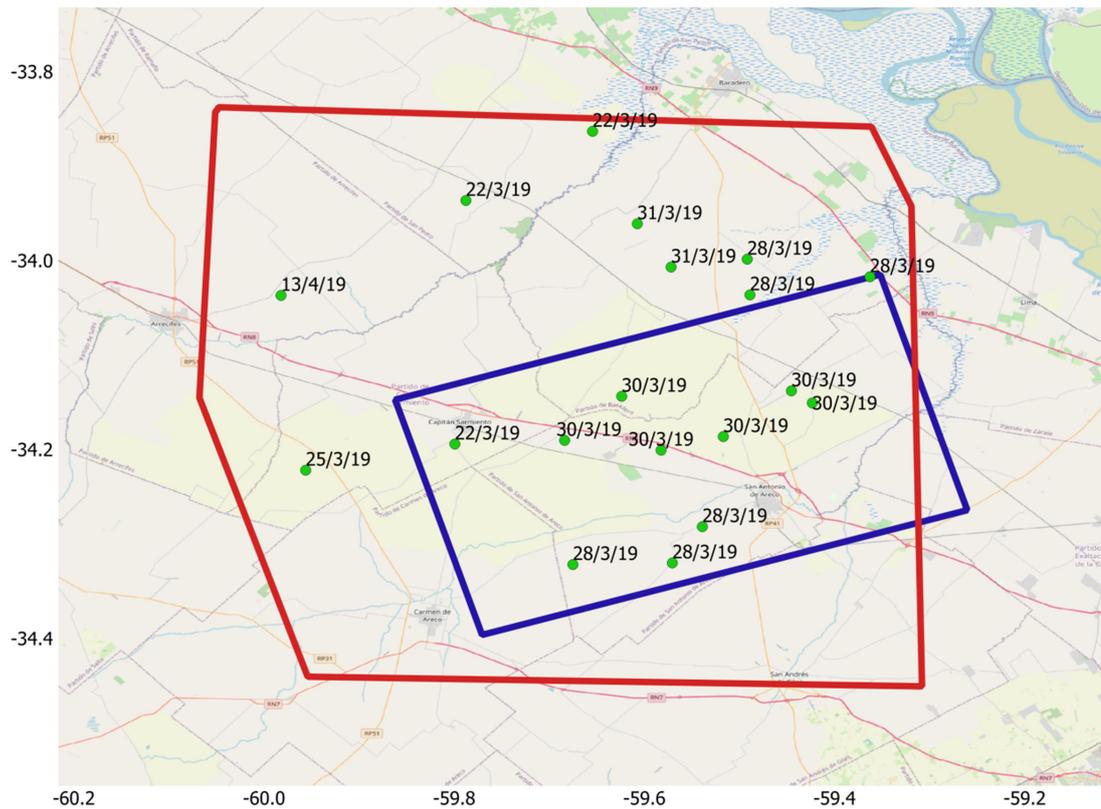


Figura 4.3. Áreas de estudio: polígono rojo: límite para la estimación de índices de rotación (a partir de mapas de secuencias de cultivos - sección 2.3.1); polígono azul: área cubierta por las escenas RADARSAT 2 obtenidas durante la campaña 2018/2019 que permiten estimar biomasa seca; puntos verdes: sitios con mediciones de carbono del suelo del Observatorio Nacional de Suelos Agropecuarios (ONSA 2023) realizadas entre marzo y abril de 2019.

El modelo de biomasa seca de soja a partir de las estimaciones de biomasa fresca y de contenido de humedad de la vegetación (sección 3.3.1) se aplicó para cada fecha de las escenas RADARSAT 2. Finalmente se aplicó una máscara de cultivos de soja de primera y de segunda a partir del Mapa Nacional de Cultivos de la campaña 2018/2019 (de Abelleira et al. 2019). Las Figuras 4.5, 4.6 y 4.7 muestran la evolución del peso fresco y seco de cultivos de soja a lo largo de la campaña 2018/2019 en el área de estudio.

4.2.3. Análisis del impacto de rotaciones

Se ajustó un modelo de regresión múltiple para identificar el efecto de los diferentes índices de rotación generados (sección 4.2.1) sobre la biomasa seca de soja. Se incluyeron covariables que describen la situación ambiental (capacidad de uso del suelo, y elevación - sección 2.2.4), y el sistema de cultivo, o sea si es soja de primera o soja de segunda. Se ajustó un modelo para cada fecha en la que se estimó biomasa de soja. En este último caso se asignó una variable categórica con valor 1 para soja de primera y valor 2 para soja de segunda.

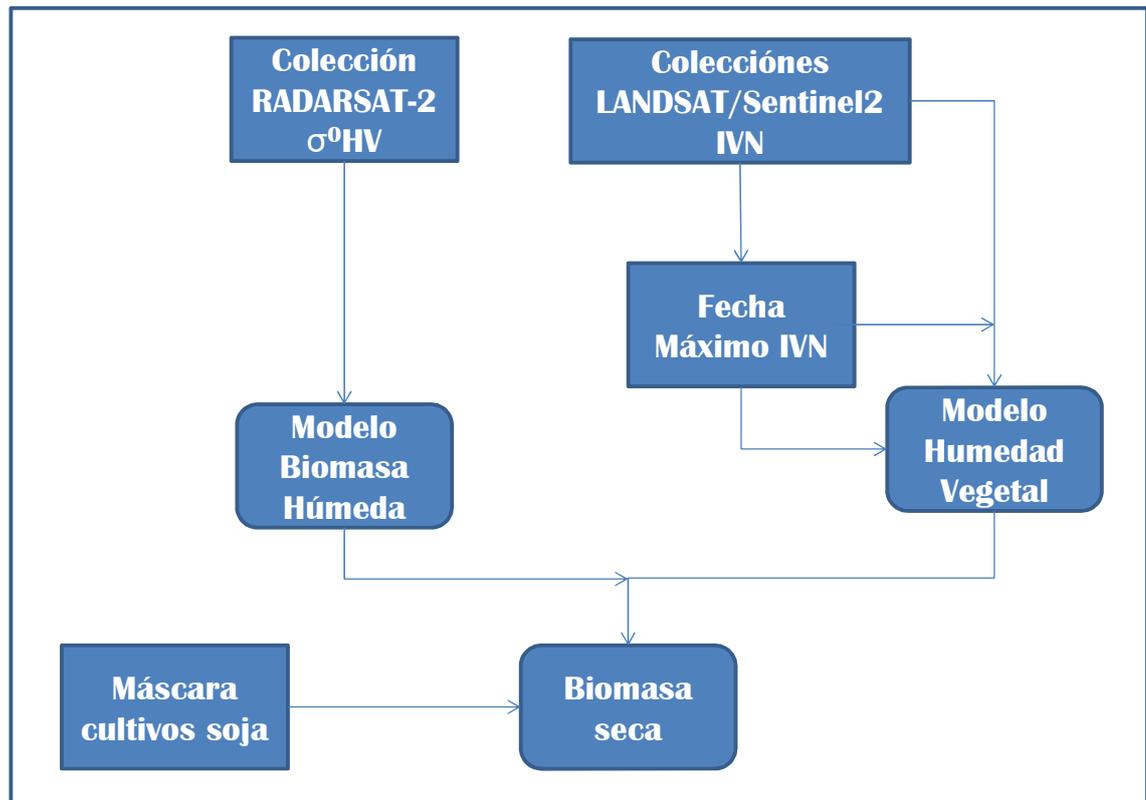


Figura 4.4. Esquema de implementación del modelo de biomasa seca a partir de información de RADAR y óptica (sección 3.3.3).

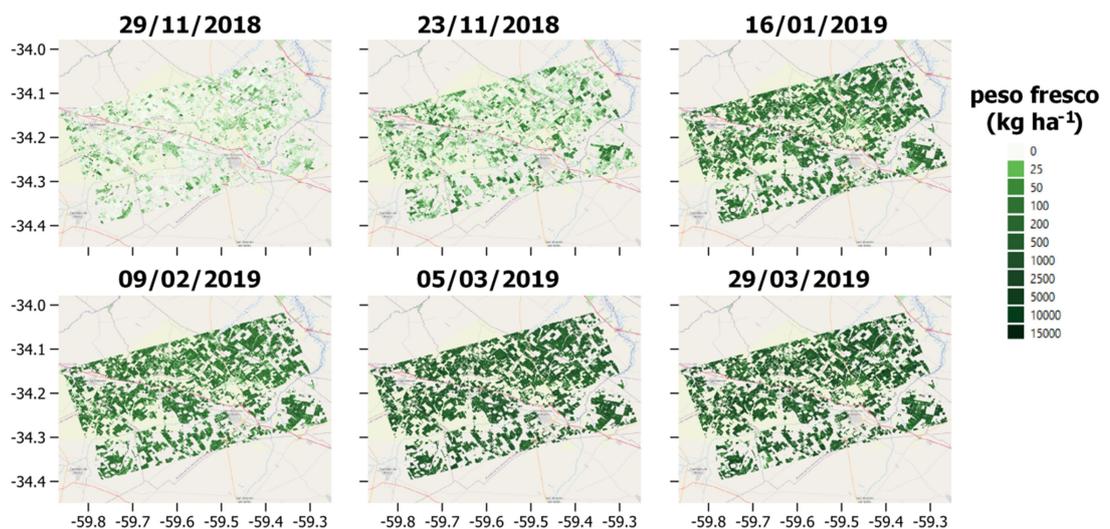


Figura 4.5. Evolución temporal de la biomasa fresca de cultivos de soja utilizando imágenes RADARSAT 2 a lo largo de la campaña 2018/2019.

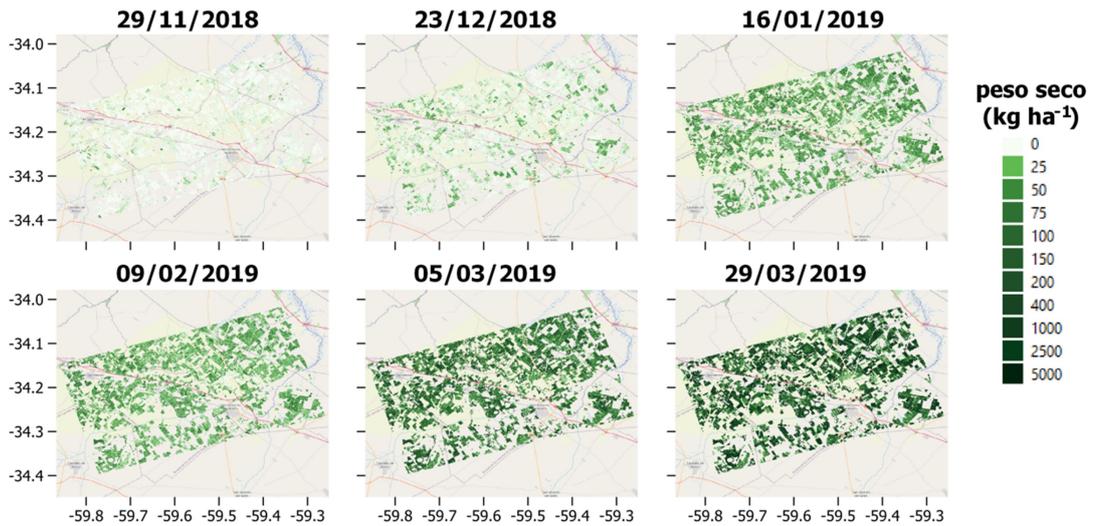


Figura 4.6. Evolución temporal de la biomasa seca de cultivos de soja utilizando el modelo que integra información de RADAR y óptica a lo largo de la campaña 2018/2019.

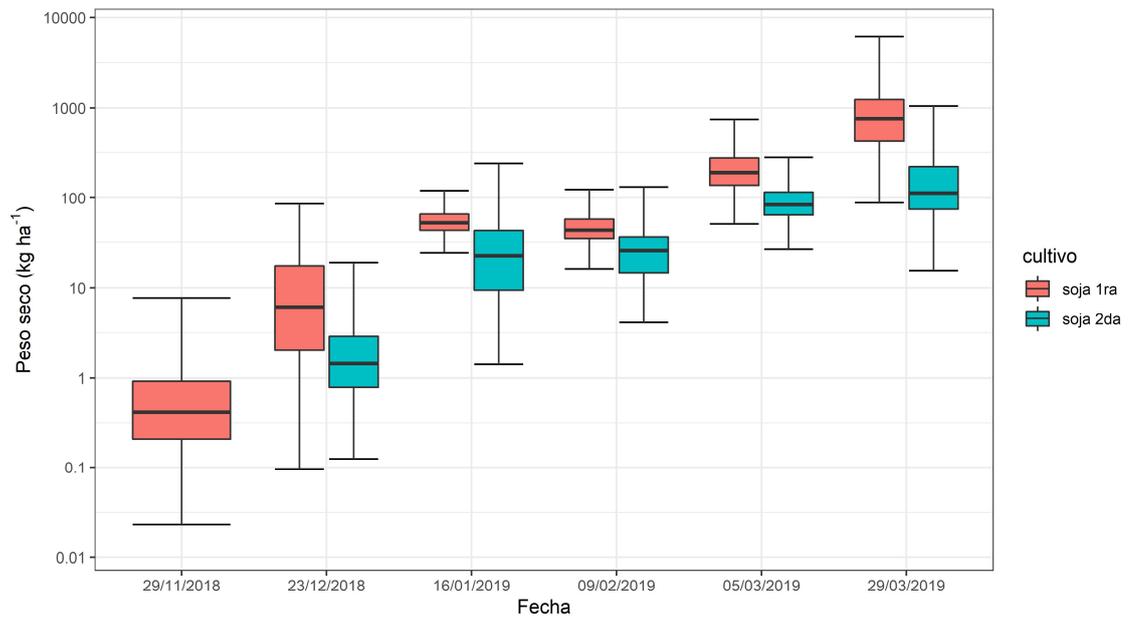


Figura 4.7. Diagramas de caja del peso fresco y seco estimado para cultivos de soja de primera y de segunda en el área de estudio a lo largo de la campaña agrícola 2018/2019.

Previo a correr el modelo de regresión múltiple de biomasa seca, se analizó la correlación entre las variables independientes (Apéndice Figura A.4.1). Dada la alta

correlación observada entre cuatro de los índices de rotación considerados: proporción de soja de primera, proporción de gramíneas en la rotación, número de períodos con rotación recomendada y número de períodos consecutivos con soja de primera, se incluyeron separadamente en modelos de regresión manteniendo el resto de las variables: intensidad de siembra, capacidad de uso del suelo y elevación. Debido a que el efecto del sistema de cultivo (soja de primera o de segunda) fue muy importante, se realizaron modelos de regresión para los casos de soja de primera y de segunda separadamente. El modelo entonces queda conformado a través de la siguiente ecuación:

$$y_i = a + b \cdot IR_j + c \cdot IS + d \cdot El + e \cdot CU \quad (1)$$

Donde y_i es la biomasa seca de soja, i indica si es soja de primera o de segunda, IR indica uno de cuatro índices de rotación j , IS es el índice intensidad de siembra, El es elevación y CU es capacidad de uso del suelo).

Para el análisis de carbono del suelo, se realizó también un análisis de regresión múltiple entre los valores de carbono del suelo medidos y el valor de los índices de rotación identificados en los sitios de medición, incluyendo como covariables la capacidad de uso y la elevación:

$$y = a + b \cdot IR_j + c \cdot IS + d \cdot El + e \cdot CU + f \cdot cult \quad (2)$$

Donde y es el carbono del suelo, IR indica uno de cuatro índices de rotación j , IS es el índice intensidad de siembra, El es elevación, CU es capacidad de uso del suelo y $cult$ si el cultivo implantado en la campaña 2018/2019 era soja de primera o soja de segunda.

Se determinaron los coeficientes estandarizados (coeficientes Beta) para evaluar el efecto de los diferentes índices y covariables en la biomasa de soja y el carbono del suelo.

4.3. Resultados

4.3.1. Impacto de las secuencias de cultivos en el crecimiento de soja

El modelo de regresión múltiple mostró mayores efectos para soja de primera, que para soja de segunda. En soja de primera, incluyendo cada uno de los cuatro índices altamente correlacionados se observó significancia estadística en la mayor parte de las fechas consideradas (Apéndice Tablas A.4.1 a A.4.4). El cuadro 4.1 muestra los parámetros ajustados para el modelo de biomasa que solo consideró la variable proporción de gramíneas entre los cuatro índices de rotación mencionados. Allí se observa que el efecto de la proporción de gramíneas fue positivo y significativo en todas las fechas, excepto la del mes de enero. La variable intensidad de siembra mostró también un efecto significativo y negativo en las fechas del 23/12/2018, 09/02/2019 y 05/03/2019. También hubo efecto significativo (y positivo) de la elevación en la fechas del 09/02/2019 y 05/03/2019. De las otras variables altamente correlacionadas (Apéndice Cuadro A.4.1 a A.4.4), el número de períodos de monocultivo de soja y la proporción de soja de primera mostraron efectos significativos y negativos en todas las fechas con excepción de enero; mientras que el número de períodos con rotación recomendada mostró efectos significativos y positivos durante las fechas de diciembre, febrero y marzo.

En soja de segunda, solo se observaron efectos significativos de los índices de rotación en la fecha de enero para proporción de soja de primera, proporción de

gramíneas (efecto positivo) e intensidad de siembra (efecto negativo) (Apéndice Cuadro A.4.5 a a.4.9). Elevación mostró también un efecto significativo y positivo en la fecha del 05/03/2019.

Cuadro 4.1. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	29/11/2018	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
proporción gramíneas	0,11**	0,23***	-0,08	0,17***	0,16***	0,14***
intensidad de siembra	-0,08	-0,1*	-0,07	-0,1*	-0,13**	-0,07
capacidad de uso	0,03	-0,02	0	0	-0,05	-0,02
elevación	-0,03	-0,03	0,03	0,17***	0,1**	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro 4.2. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
proporción gramíneas	-0,03	0,11*	0,03	-0,05	0,01
intensidad de siembra	0,07	-0,18***	-0,05	-0,02	-0,01
capacidad de uso	0,01	0,07	0,04	0,04	0,05
elevación	0	-0,03	-0,01	0,08*	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

4.3.2. Impacto de las secuencias de cultivo en el carbono del suelo

El modelo de regresión de carbono, también requirió considerar separadamente las mismas cuatro variables altamente correlacionadas que para el modelo de biomasa seca (Apéndice Figura A.4.2). Se observó un efecto significativo y negativo en el índice intensidad de siembra y en elevación. De los cuatro índices más correlacionados entre sí, ninguno mostró significancia al 0.05. Mostraron significancia negativa al 0.1 los índices proporción de soja de primera y número de períodos de monocultivo de soja (Cuadro 4.3, Apéndice Cuadros A.4.9 a A.4.12), mientras que no se observó efecto en la proporción de gramíneas ni en el número de períodos con rotación recomendada.

Cuadro 4.3. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico en los primeros 20 cm del suelo. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	Carbono Orgánico
períodos monocultivo de soja	-0,44•
intensidad de siembra	-1,29**
capacidad de uso	0,02
elevación	-0,97*
cultivo	0,03

** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

4.4. Discusión

Los índices considerados en este capítulo, que describen diferentes situaciones de historia de siembra a lo largo de siete campañas, mostraron un efecto significativo en la biomasa seca de cultivos de soja. Esto fue mucho más notable al observar el crecimiento en cultivos de soja de primera que en cultivos de soja de segunda. El cultivo de soja de segunda se realiza en siembra directa inmediatamente luego de la cosecha de un cultivo de invierno como el trigo, que produce una demanda de agua y

nutrientes previa, que puede no ser compensada al no existir un período de barbecho previo al cultivo de soja. Es así que el crecimiento del cultivo de verano subsiguiente puede estar mucho más limitado por las condiciones particulares del año (e.g. lluvias durante el período de crecimiento de la soja), y tener menos efecto otros aspectos de respuesta más lenta como la capacidad de retención hídrica del suelo (que define la acumulación de agua durante el barbecho), y que puede ser afectada con la historia de uso del suelo. Por otro lado, Calviño et al. (2003) señala un efecto muy relevante del atraso en la fecha de siembra, un aspecto del manejo, sobre el rendimiento de soja de segunda por encima de otras variables ambientales que podrían haberse modificado por efecto de la secuencia de cultivos.

Los índices de rotación mostraron efectos en producción de biomasa (incremento o disminución) en la dirección esperada en estos casos:

- i) incremento de biomasa con aumento en número de períodos con rotación recomendada y con aumento en proporción de gramíneas;
- ii) disminución de biomasa con aumento en el número de períodos con monocultivo de soja y con aumento en proporción de soja.

A pesar de que la intensidad de siembra (i.e. número de cultivos por año) está correlacionada positivamente con el número de períodos con rotación y con la proporción de gramíneas, y correlacionada negativamente con la proporción de soja de primera y número de períodos con monocultivo de soja (Apéndice Figura A.4.1), no mostró una respuesta en el sentido de estos índices. Por el contrario, la intensidad de siembra mostró una respuesta negativa en biomasa seca. En regiones húmedas con una larga estación de crecimiento como en la Pampa Ondulada, un mayor número de cultivos por año, puede disminuir sensiblemente los tiempos de barbecho (Novelli et al.

2017). Esto generaría una menor disponibilidad de tiempo para la acumulación de agua o mineralización de nutrientes, pudiendo generar disminuciones de productividad. También es posible que en suelos de baja productividad, no sea posible la siembra de maíz debido a su alta sensibilidad ambiental (Maddoni et al. 1999; Zeljkovich 2015), brindando como únicas opciones de rotación en esta región a soja de primera y el doble cultivo trigo-soja. Esto podría explicar que existan casos con alta intensidad de siembra, pero con baja producción de biomasa por tratarse de suelos de baja productividad.

La magnitud del efecto de los índices de rotación pone en evidencia la capacidad de estos sistemas de transferir información en el tiempo (desde una historia de siete campañas), en particular en sistemas con relativamente baja utilización de insumos como es la siembra de soja en Argentina (Satorre 2011; Novelli et al. 2023), y en condiciones que permiten reflejar diferencias ambientales debidas a diferente historial de siembra (e.g. planteos de soja de primera que permiten acumular agua durante el barbecho). Esto también señala la importancia de la historia de uso frente a aspectos que describen las condiciones del ambiente como la Capacidad de Uso del suelo (que esta zona muestra en similar magnitud, suelos de clases 2 (aptitud alta agrícola) y 3 (Aptitud media/alta agrícola-ganadera) y la elevación que guarda relación con la dinámica del agua y la profundidad del suelo. Otros autores mostraron efectos ambientales complementarios al de la historia de uso, variando su magnitud según la temperatura, precipitaciones o características edáficas. Kluger et al. (2022) utilizando una combinación de información de campo e imágenes satelitales observó que el efecto de secuencias de cultivos en el rendimiento fue diferente según la temperatura y precipitaciones. Zhao et al. (2020) utilizando un conjunto de datos de experimentos obtenidos de una recopilación bibliográfica identificó que también las condiciones edáficas afectaron la respuesta en rendimiento a la rotación. Los resultados de este

capítulo muestran que los índices de rotación generados explicaron variaciones en el crecimiento de soja a pesar de la variabilidad ambiental y de condiciones de manejo en el área de estudio.

El análisis de regresión múltiple considerando las muestras obtenidas de carbono orgánico del suelo, mostró contrariamente a lo esperado, una relación negativa con la variable intensidad de siembra (número de cultivos por año), y un efecto significativo (solo $p < 0,1$) para las variables proporción de soja de primera y número de períodos con monocultivo de soja. Al existir un mayor número de cultivos por año, se espera que la cantidad de rastrojos sea alta, permitiendo mayores ingresos de carbono al sistema, y a su vez que el suelo se mantenga cubierto durante gran parte del año, disminuyendo posibles pérdidas de carbono por erosión o efectos de la radiación solar. Sin embargo, los resultados obtenidos aquí podrían indicar que la siembra de múltiples cultivos en un año sea consecuencia de una restricción por el empobrecimiento de los suelos. Por ejemplo, un deterioro del suelo tal que ya no permita sembrar maíz (que se considera el de mayores requerimientos entre trigo-soja y soja de primera), permitiría solo la siembra de trigo-soja o soja de primera. Una mayor frecuencia de trigo-soja en detrimento de maíz podría incrementar el valor de intensidad de siembra.

No se observó respuesta del carbono del suelo a los índices relacionados con la proporción de soja en la secuencia. Es posible que la variable carbono del suelo sea mucho más lenta que otras variables que también generen respuesta en crecimiento y rendimiento de cultivos. Novelli et al. (2011) observó que el incremento en la frecuencia de soja en secuencias de cultivo en Molisoles no modificó el carbono del suelo, pero si afectó la proporción de tamaños de agregados, disminuyendo la cantidad de macroagregados. Zuber et al. (2015) También encontraron cambios en la estabilidad

de agregados sin que se modifique el carbono orgánico del suelo por efecto de la rotación de cultivos.

El rango de valores de carbono orgánico medido estuvo entre 1,05 y 2,02 % con un promedio de 1.58 %, valores relativamente bajos en comparación con suelos vírgenes en Pampa Ondulada (Andriulo et al. 1999). Este autor observó una disminución y luego estabilización del carbono del suelo luego de cinco a diez años de agricultura continua, no mostrando efecto de las secuencias de cultivos evaluadas. Dado que esta región en particular viene siendo explotada para la agricultura desde hace décadas e incluso hace más de un siglo (Balsa 2001, Viglizzo et al. 2004; Djenderedjian 2008), podría ocurrir que ya existan suelos empobrecidos por el excesivo uso y que la respuesta en carbono del suelo a la rotación sea baja.

Debe considerarse también que el número disponible de muestras de suelo puede no ser representativo de las diferentes condiciones ambientales y de manejo en el sitio de estudio. A diferencia de la variable respuesta de crecimiento de cultivos que incluye información de toda el área de estudio, la utilización de mediciones puntuales, a su vez sin conocer el manejo específico de cada sitio, podría hacer que algún factor de manejo en algunos puntos de medición influya en gran medida en el resultado del análisis.

4.5. Conclusiones

En este capítulo se logró la implementación de los modelos desarrollados en el capítulo III (secciones 3.3.1 y 3.3.3.) en un área determinada, pudiendo generar mapas de biomasa fresca y seca de cultivos de soja durante una campaña agrícola. Esto permitió realizar un análisis del impacto de diferentes secuencias de siembra sobre la producción de biomasa en un área determinada, incluyendo un gran número de

situaciones representativas de lo ocurrido en la zona de estudio. También se analizó el impacto de las secuencias de cultivos sobre una variable ambiental como el carbono del suelo, pero a partir de muestras puntuales, posiblemente con menor representatividad.

Con respecto a las hipótesis planteadas en la sección 1.2, se confirmó que un sistema con relativamente escasa utilización de insumos como el cultivo de soja, que generalmente no recibe fertilización nitrogenada (Satorre 2011; Novelli et al. 2023), puede mostrar respuesta a una historia de uso de más de siete años. Esto se observó particularmente en los sistemas de soja de primera, y con menor frecuencia en sistemas de soja de segunda. Es posible que en este último caso, el cultivo se vuelva muy dependiente de las condiciones del año, dado que el sistema no tiene capacidad de almacenamiento previo de agua, al no existir prácticamente un barbecho previo al cultivo. También está indicando la importancia de un efecto de la historia reciente de siembra como lo es el cultivo antecesor.

Si bien en las predicciones de esta tesis (sección 1.2), se esperaba que en sistemas con menor rotación y más preponderancia de cultivos de soja de primera, existan a largo plazo pérdidas de carbono del suelo, los resultados obtenidos a partir de la información disponible, no permiten concluir que el carbono del suelo disminuya en estos casos. Dada la respuesta observada en producción de biomasa de soja de diferentes secuencias de rotación, se puede inferir que la secuencia de cultivos haya afectado alguna otra característica del suelo, no relacionada directamente con el contenido total de carbono, como por ejemplo la capacidad de retención hídrica que está asociada a la distribución de tamaño de agregados y porosidad.

Capítulo V

Análisis de secuencias de cultivos a escala nacional

5.1. Introducción

En Argentina hasta hace muy pocos años, no existía información detallada y continua sobre la distribución de cultivos a escala nacional. La información de área sembrada o rendimiento y producción de cultivos se encontraba sólo a nivel de departamento (MINAGRI, 2017). Los mapas de cultivos que habían sido generados fueron de áreas o regiones relativamente pequeñas, y en momentos puntuales (e.g. Caride y Paruelo 2007; King et al. 2017). A partir del año 2018, el INTA viene generando en forma consecutiva, mapas de cultivos en alta resolución (permite identificar lotes) de las principales regiones agrícolas de Argentina (de Abelleira et al. 2019; 2020b; 2021). La metodología de realización de los mismos fue similar a la descrita en la sección 2.2 de esta tesis, incluyendo relevamientos a campo desde vehículos a lo largo de caminos predefinidos y clasificaciones supervisadas a partir de índices derivados de imágenes satelitales.

Desde hace varias décadas que se dispone de información que hubiera permitido la caracterización detallada de la cobertura del suelo a escala nacional o global. Sin embargo, solo en tiempos muy recientes se generaron este tipo de productos a gran escala (e.g. Baeza et al. 2022; Graesser et al. 2022) siendo diversas las posibles causas, entre las que se pueden incluir las dificultades de acceso a las imágenes, limitada capacidad de almacenamiento e insuficientes recursos para el procesamiento de la información.

Existen desde la década de 1970 satélites de observación de la tierra como los sistemas Landsat, cuyo inicio se remonta al año 1972 con el lanzamiento de la plataforma satelital Landsat 1 y el posterior lanzamiento de plataformas sucesivas (Lauer et al. 1997). Los primeros sistemas tenían una resolución espacial de 80 metros,

y a partir de 1985 con el Lanzamiento de la plataforma Landsat 5 el sistema pasó a tener 30 metros de resolución y sensores de características similares a los existentes hoy en día (e.g. Landsat 9). La apertura del catálogo Landsat (libre disponibilidad de imágenes) en el año 2008 generó un fuerte incremento en la descarga de sus escenas, que se incrementó 100 veces en una década (Wulder et al. 2012). También la política de distribución del sistema Copernicus, que incluye una plataforma de características similares a Landsat como Sentinel 2 disponible desde el año 2015, es de acceso abierto (Aschbacher 2017).

Por otro lado, la gran disponibilidad de sistemas de almacenamiento y procesamiento en la nube con gran capacidad de cómputo (Gorelick et al. 2017) facilitó tanto el pre-procesamiento de las imágenes por parte de los proveedores de imágenes (e.g. orto-rectificación automática de escenas), como el procesamiento y análisis directo dado por parte de usuarios. Es así que actualmente al no existir la limitante de disponibilidad o de procesamiento, es clave la capacidad de organizar esta información y vincularla con observaciones terrestres para generar productos y evaluar su calidad.

Las nuevas herramientas y productos disponibles sobre Argentina como mapas secuenciales de tipo de cultivo a escala nacional aportan información sin precedentes en cuanto a detalle y extensión espacial y disponibilidad temporal sobre la distribución de cultivos (Figura 5.1). Permiten entre otras cosas analizar secuencias de cultivos e identificar en que regiones o sitios, y en qué magnitud se presentan diferentes prácticas como el monocultivo o la rotación. Esto permitirá identificar si estas situaciones ocurren en zonas centrales o marginales y relacionarlas con las características ambientales y humanas de las diferentes regiones, y a así aportar a la caracterización de la sustentabilidad de los sistemas agrícolas de Argentina.

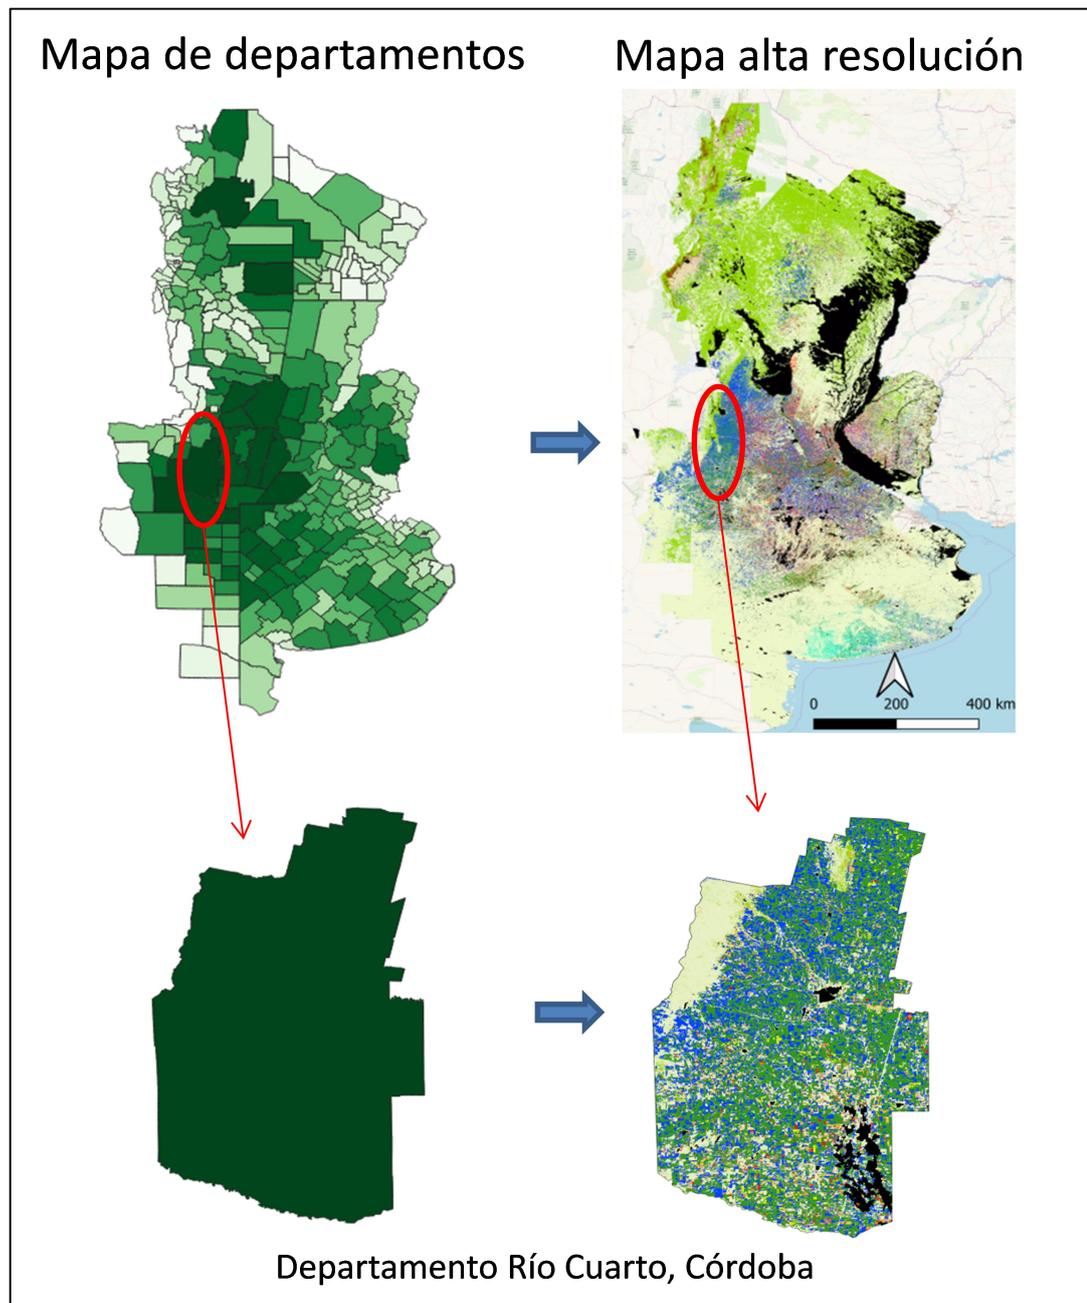


Figura 5.1. Esquema de cambio en la disponibilidad de información a partir de mapas en alta resolución (que permiten identificar lotes) frente a la disponibilidad de información a nivel de departamento.

El objetivo de este capítulo es la caracterización de secuencias de cultivos a escala nacional y analizar su relación con variables espacialmente explícitas como la precipitación y la distancia a puertos de exportación de granos.

5.2. Materiales y Métodos

Se generaron diversos índices a partir de secuencias de cultivos disponibles a escala nacional. Se utilizaron los mapas de cultivos de Argentina de las campañas 2018/2019, 2019/2020 y 2020/2021 generados por el INTA (de Abelleira et al. 2019; de Abelleira et al. 2020b; de Abelleira et al. 2021). Estos mapas fueron realizados a partir de clasificaciones supervisadas mediante imágenes satelitales de la plataforma Landsat y utilizando muestras de entrenamiento y validación a partir de relevamientos a campo a lo largo de caminos y rutas distribuidas a lo largo de 15 zonas que incluyen las principales regiones agrícolas de Argentina (Zonas PAS – Bolsa de Cereales de Buenos Aires, 2019). Para la campaña 2018/2019 se publicó un único mapa que describe toda la campaña, mientras que para el resto de las campañas se publicaron separadamente mapas de invierno y de verano. Para este análisis se unificaron los mapas de invierno y verano de las campañas 2019/2020 y 2020/2021 en un único mapa por campaña. De esta manera se establecieron las clases descriptas en el Cuadro 5.1 en cada uno de los mapas finales (Figura 5.1).

Cuadro 5.1. Clases de los mapas unificados por campaña a partir de los Mapas Nacionales de Cultivos de las campañas 2018/2019, invierno 2019, verano 2020, invierno 2020 y verano 2021.

Clase	Descripción
Maíz	Único cultivo sembrado en la campaña.
Soja 1ra	Único cultivo sembrado en la campaña.
CI-Soja	Doble cultivo con cultivos de invierno (trigo, cebada, centeno, avena, verdeos de invierno o cultivos de cobertura) y soja como cultivo de verano.
CI-Maíz	Doble cultivo con cultivos de invierno (trigo, cebada, centeno, avena, verdeos de invierno o cultivos de cobertura) y maíz como cultivo de verano.
MANI	Único cultivo sembrado en la campaña.
Girasol	Único cultivo sembrado en la campaña.
CI sin cultivo de verano	Cultivos de invierno (trigo, cebada, centeno, avena verdeos de invierno o cultivos de cobertura), siendo el único cultivo sembrado en la campaña.
Ganadería	Tierras no agrícolas. Incluye pasturas y pastizales naturales y leñosas nativas e implantadas.
Algodón	Único cultivo sembrado en la campaña.
Poroto	Único cultivo sembrado en la campaña.
Caña	Único cultivo presente en la campaña.
Girasol-CV	Doble cultivo de girasol y un cultivo de verano (solo en Zona II - NEA).
Máscara	Incluye cuerpos de agua, zonas inundables y áreas urbanas.

Se consideraron los siguientes índices para su análisis:

- Proporción de soja de primera: se cuantificaron las campañas en que se observó soja de primera (cultivo único) en proporción al total de campañas.
- Número de secuencias de rotación: se cuantificó el número de sub-períodos consecutivos de dos años (i.e. 2018/2019 a 2019/2020 y 2019/2020 a 2020/2021) en que se observó un cambio en la clase de cultivo.
- Intensidad de siembra: promedio del número de cultivos por año (total de cultivos identificados sobre el total de campañas).
- Diversidad de cultivos: número de especies no repetidas identificadas durante las tres campañas.

Dado que el área cubierta por los mapas de las distintas campañas sufrió modificaciones, se consideró solamente la intersección del área mapeada en las 3 campañas para este análisis. Esto implicó que no se incluya en el análisis a la provincia de Corrientes dado que no fue clasificada durante la campaña 2018/2019.

Se consideraron variables espacialmente explícitas para evaluar si existe relación con los índices de rotación generados. Se utilizó la precipitación media anual de las 3 campañas analizadas, considerando el 1 de junio de cada año y el 31 de mayo del año siguiente como inicio y fin de la campaña, respectivamente. La información fue obtenida de la base de datos CHIRPS a paso diario y con una resolución de 5 Km (Figura 5.3.b). También se generó una capa de distancia a puertos a partir de información de ubicación de puertos provista por el Instituto Geográfico Nacional de Argentina. El mapa se realizó con un píxel de 5 Km (Figura 5.3.a). El análisis incluyó un modelo de regresión lineal simple y un análisis de frecuencia de casos para las variables consideradas.

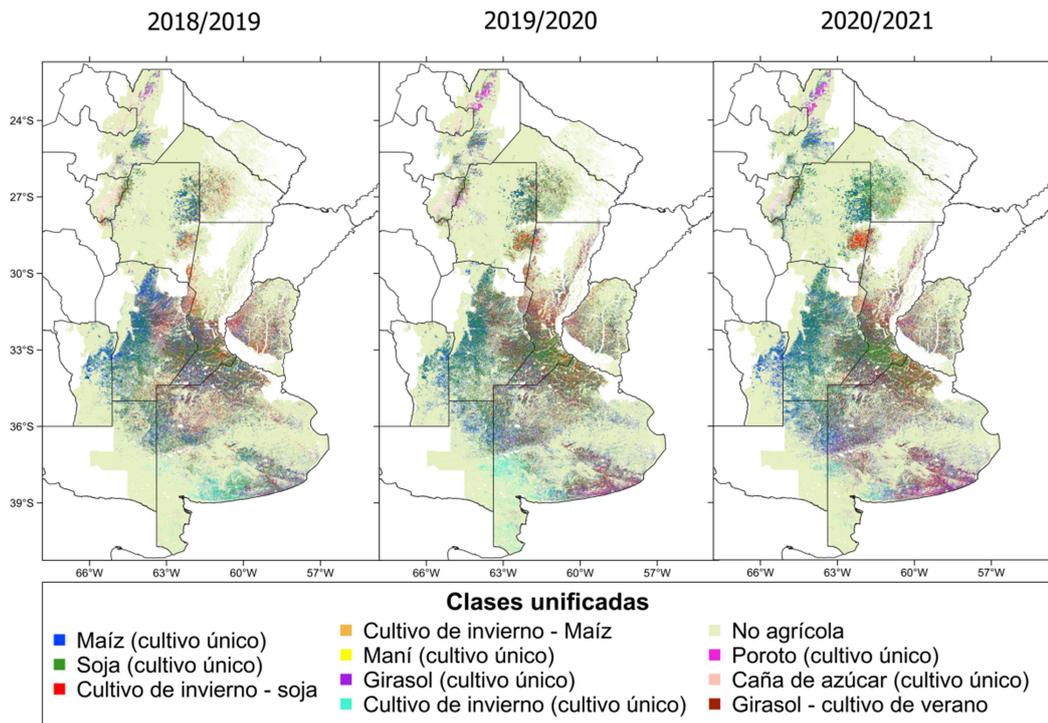


Figura 5.2. Mapas unificados por campaña (incluyendo cultivos de invierno y verano) a partir del Mapa Nacional de Cultivos para las campañas 2018/2019, 2019/2020 y 2020/2021.

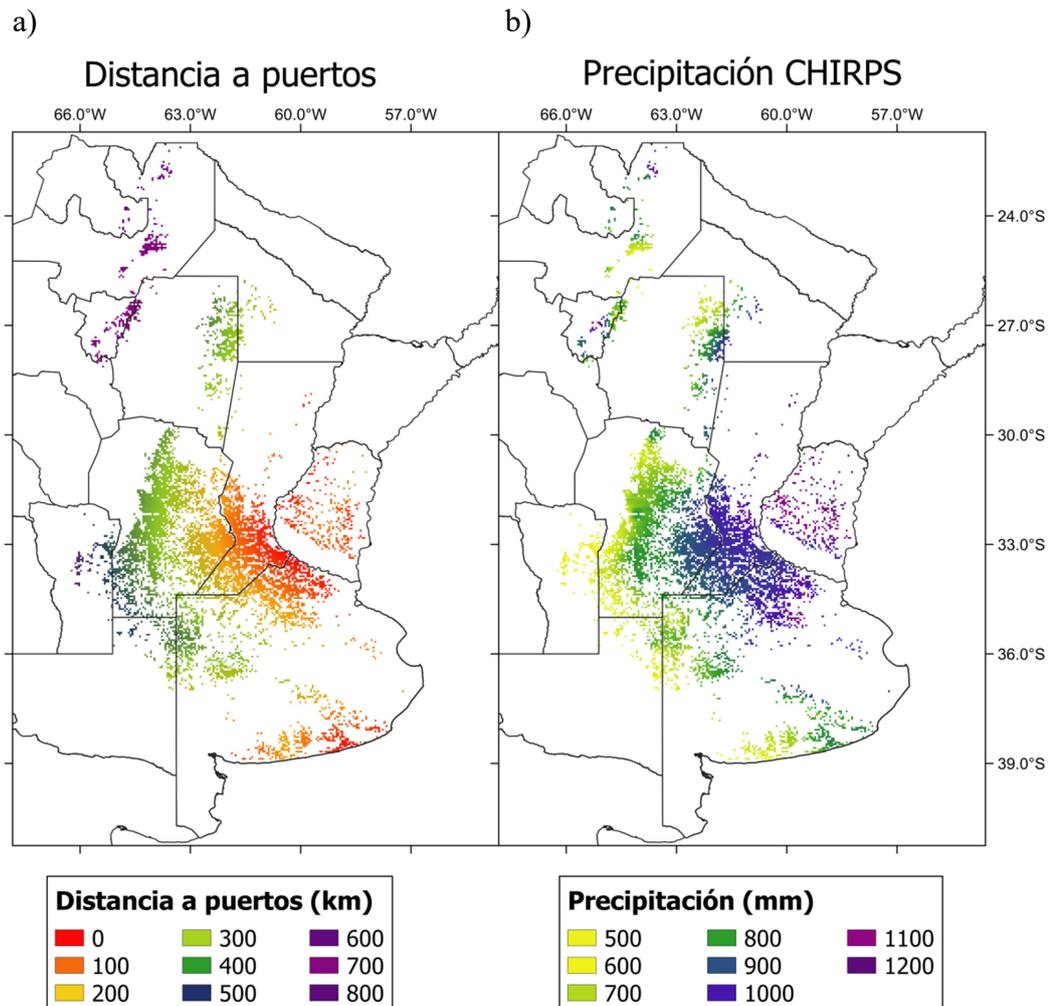


Figura 5.3.a) Distancia a puertos (a partir de información de ubicación de puertos provista por el Instituto Geográfico Nacional de Argentina); b) Precipitaciones totales (promedio por campaña) durante las tres campañas analizadas (2018/2019, 2019/2020 y 2020/2021) a partir de la base de datos CHIRPS. Se mapearon solamente las áreas agrícolas.

5.3. Resultados

El mapa de índice de diversidad de cultivos (Figura 5.4.a) muestra que los casos más frecuentes estuvieron entre uno (sin cambio en el cultivo) y tres cultivos diferentes

durante el período analizado. Se observan casos de un solo cultivo (i.e. sin rotación) principalmente en dos sectores, en el Noroeste Argentino en relación a las plantaciones de caña de azúcar (Figura 5.2) y en un sector de la zona núcleo asociado a la alta proporción de soja de primera (Figura 5.5.a); mientras que la presencia de casos de tres cultivos se identifica principalmente en sectores de precipitación intermedia y alta (Figuras 5.3.b y 5.4.a). La intensidad de siembra (i.e. número de cultivos por campaña), mostró los menores valores (i.e. un cultivo por campaña) en el límite oeste y sudoeste de la región Pampeana, este de Salta, noreste de Santiago del Estero, y en parte de la zona núcleo (Figura 5.4.b). Con excepción de la zona núcleo, el patrón de distribución de zonas con un cultivo por campaña estuvo asociado a sectores con menores precipitaciones (Figura 5.3.a). Se observan regiones con predominancia de casos de alta intensidad de siembra en sudeste de Santiago del Estero y norte de Santa Fé y oeste de Entre Ríos donde el nivel de precipitaciones es elevado. Con respecto a la proporción de soja de primera, se observa una alta frecuencia de casos con alta proporción (soja de primera durante dos o tres períodos) en parte de la zona núcleo en el sur de Santa Fé y en noreste de Buenos Aires, coincidente también con sitios con poca rotación (baja diversidad de cultivos) y cercanos a puertos (Figuras 5.5.b, 5.5.a y 5.3.a).

Se analizó la frecuencia de casos con distinta proporción de soja de primera según un gradiente de distancias a puertos para las diferentes zonas consideradas en el Mapa Nacional de Cultivos (Figura Apéndice A.5.2). Dentro de la zona núcleo (norte de Buenos Aires, sur de Santa Fé y sudeste de Córdoba – Zonas VI y VII del Mapa Nacional de Cultivos), se identificó una relación positiva y significativa del área de casos con baja proporción de soja de primera (0,33) con la distancia a puertos, es decir un aumento del área de casos en la medida que se ubicaron más lejos de los puertos (Cuadro 5.2), En cambio, el área de casos con moderada a alta proporción de soja de

primera (valores de 0,66 y 1) mostraron una relación negativa y significativa con la distancia a puertos, es decir que aumentó el área de casos en la medida que se ubicaron más cerca de los puertos (Cuadro 5.2). La Figura 5.6 muestra una distribución de frecuencias con mayor cantidad de casos con alta proporción de soja de primera (valores de 0,66 y 1) en sectores más cercanos a los puertos, que en sectores más alejados. No ocurrió lo mismo con los casos con un año de soja de primera, que mostraron una distribución más uniforme en el rango de distancias a puertos considerado.

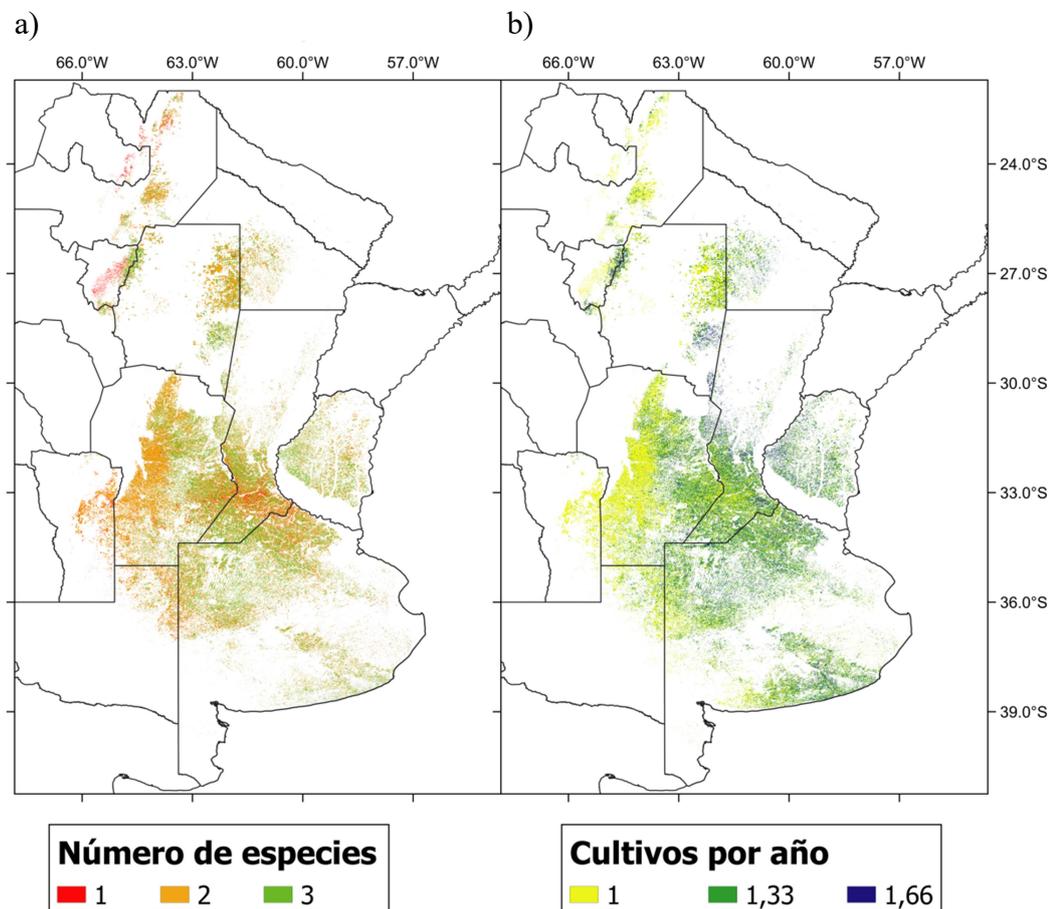


Figura 5.4. Número de especies sembradas (a) e intensidad de siembra (promedio del número de cultivos por campaña - b) a lo largo de las tres campañas agrícolas consideradas (2018/2019, 2019/2020 y 2020/2021).

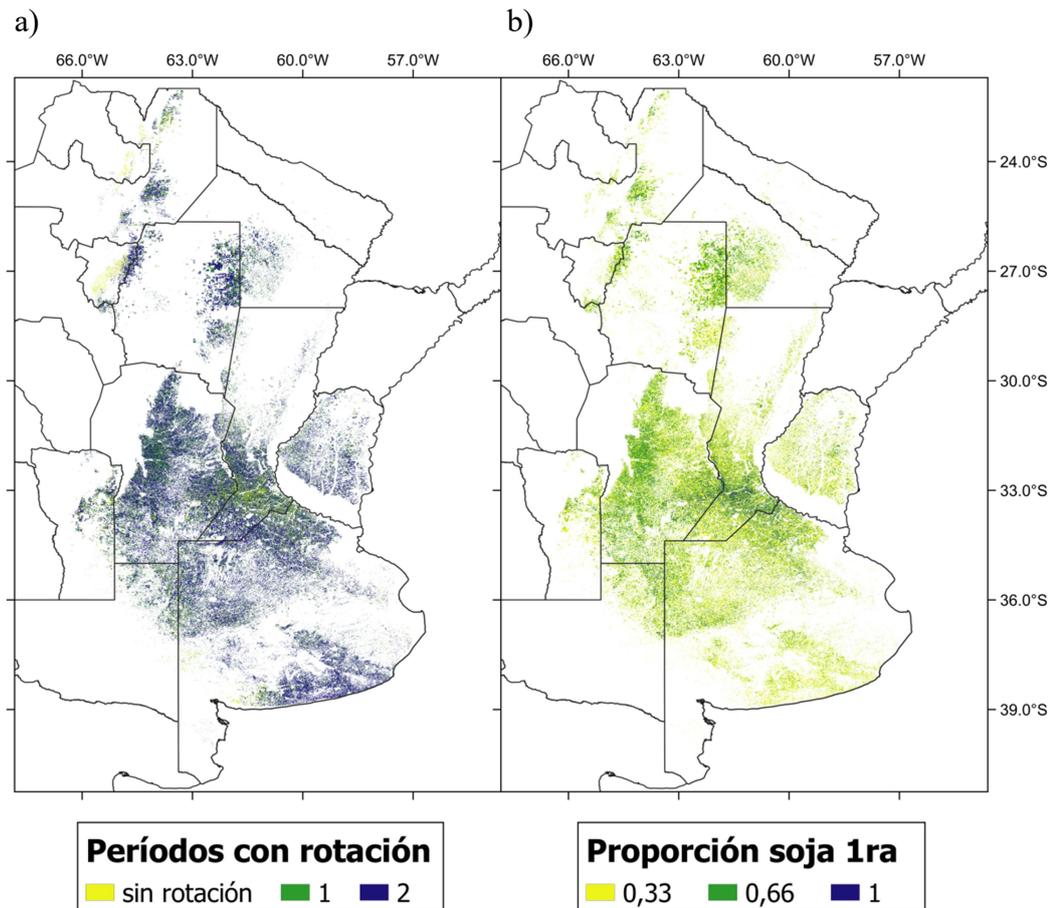


Figura 5.5. Número de secuencias (sub-períodos de dos años) que mostraron rotación (cambio en el cultivo identificado - a) y proporción de la clase soja de primera (cultivo único - b) durante las tres campañas agrícolas consideradas (2018/2019, 2019/2020 y 2020/2021).

Cuadro 5.2. Coeficientes de regresión lineal simple entre distancia a puertos y área cubierta con distintas proporción de siembra de soja de primera sembrada durante las tres campañas analizadas.

Proporción de soja de primera	0,33	0,66	1
Distancia a puertos	14.082***	-4.274***	-6.0345**

***significancia al 0,001

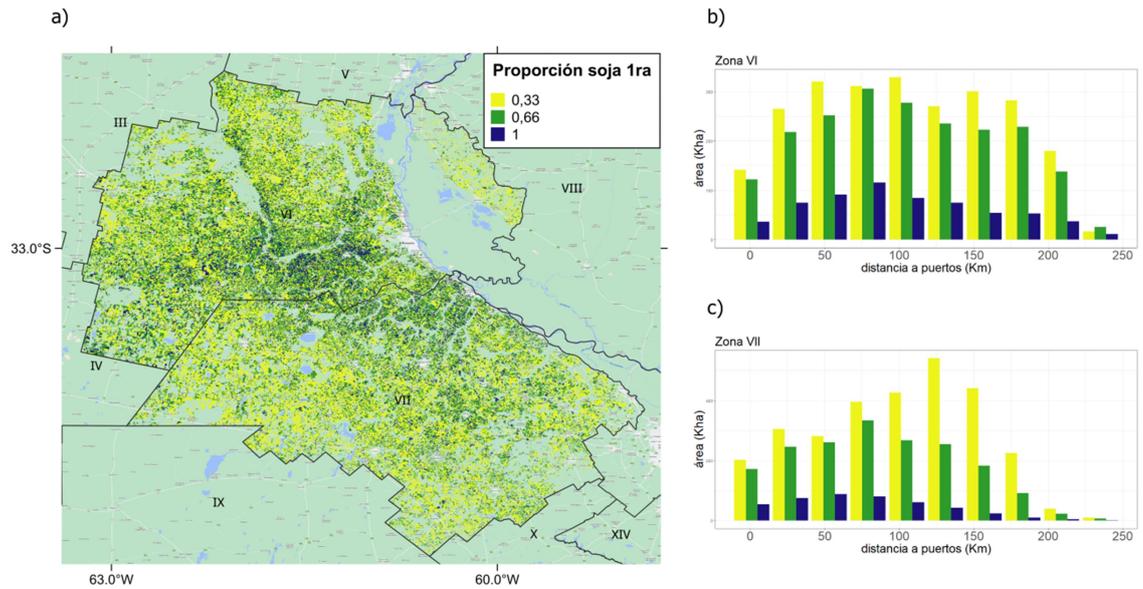


Figura 5.6.a) Casos con diferente proporción de soja de primera durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) en Zona Núcleo (zonas VI y VII del Mapa Nacional de Cultivos (de Abelleira et al. 2019)). Área de casos con diferente proporción de soja de primera durante las tres campañas agrícolas analizadas a lo largo de un gradiente de distancia a puertos: b) Zona VI: Núcleo Norte, c) zona VII: Núcleo Sur.

Se identificó una relación negativa y significativa entre la precipitación media anual y el área de casos con intensidad de siembra de 1 (1 solo cultivo por campaña – Cuadro 5.3). Intensidades de siembra de 1,33 y 1,66 mostraron, por el contrario, relaciones positivas y significativas con la precipitación media anual (Cuadro 5.3). El histograma de frecuencias muestra que no se observaron prácticamente zonas con más de un cultivo por año con precipitaciones menores a 600 mm anuales (Figura 5.7). A medida que aumentó la precipitación, se observaron más casos de 1,33 y 1,66 cultivos por año (muy escasos estos últimos por debajo de 700 mm anuales). Si bien los casos de un cultivo por año disminuyeron por encima de 700 mm, se mantuvieron relativamente altos en comparación con otras intensidades de siembra.

Cuadro 5.3. Coeficientes de regresión lineal simple entre precipitación media anual y área cubierta por cada una de las intensidades de siembra consideradas.

Intensidad de siembra	1 cultivo por año	1,33 cultivos por año	1,66 cultivos por año
precipitación	-8.1231***	6.4092***	3.0924**

***significancia al 0,001

El número de especies sembradas también mostró asociación con la precipitación (Figura 5.8). El modelo de regresión no identificó un efecto significativo de la presencia de una única especie en las precipitaciones (Cuadro 5.4). Se observó un efecto negativo y significativo de la precipitación a casos con dos especies, y un efecto positivo y significativo a casos con tres especies sembradas, es decir que mostró un aumento de casos con tres especies con el aumento de la precipitación (Cuadro 5.4). Prácticamente no se observaron casos de siembra de tres especies (durante las tres campañas analizadas) por debajo de 600 mm (Figura 5.8). En rangos de precipitación intermedios y altos, la distribución de casos con dos o tres especies fue similar. Casos de una única especie sembrada (i.e. monocultivo) presentaron más estabilidad a lo largo del gradiente de precipitación, mostrando los valores más altos en el rango de 900 a 1000 milímetros, coincidente con la precipitación anual de la zona núcleo agrícola.

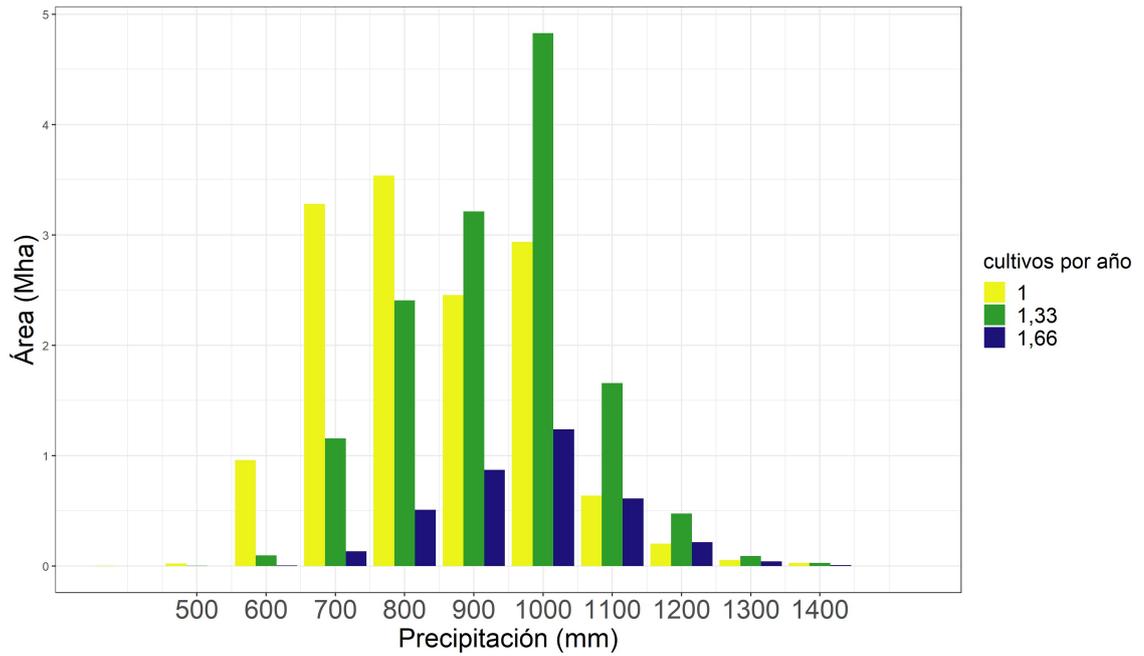


Figura 5.7. Área de casos con diferente intensidad de siembra (número de cultivos por año) durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) a lo largo de un gradiente de precipitación media anual sobre las principales regiones agrícolas de Argentina.

Cuadro 5.4. Coeficientes de regresión lineal simple entre precipitación media anual y área cubierta según el número de especies identificado durante las tres campañas analizadas.

Intensidad de siembra	1 especie	2 especies	3 especies
precipitación	0.08156	-2.628***	5.3331**

***significancia al 0,001

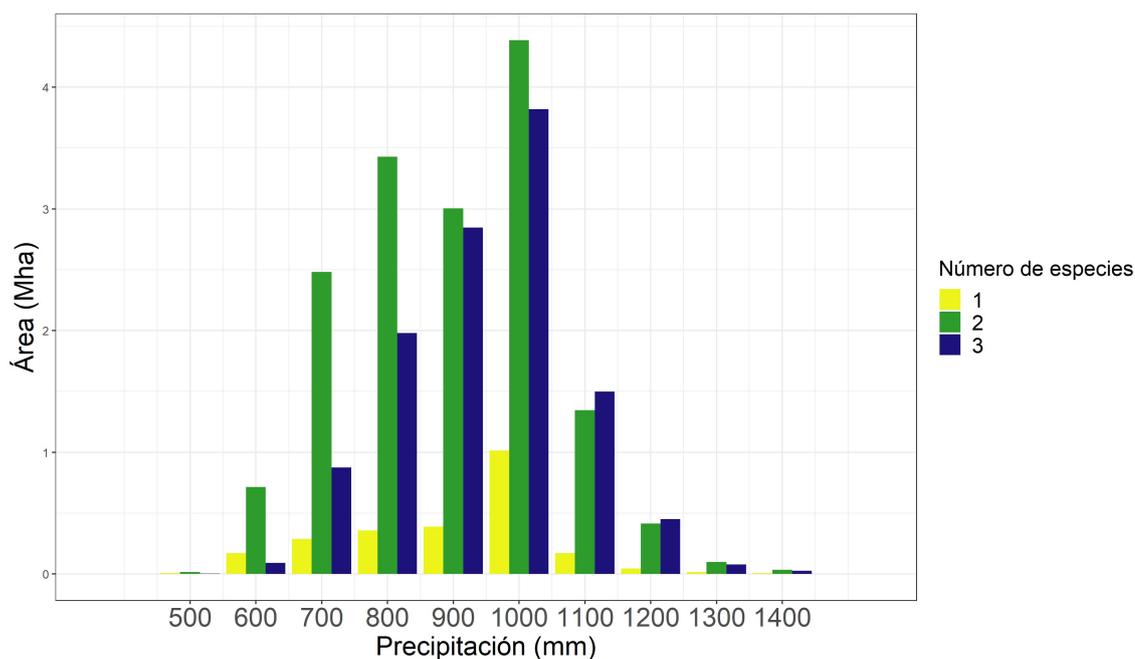


Figura 5.8. Área de casos con diferente número de especies durante las tres campañas agrícolas analizadas (2018/2019, 2019/2020 y 2020/2021) a lo largo de un gradiente de precipitación media anual sobre las principales regiones agrícolas de Argentina.

5.4. Discusión

En particular en zona núcleo, se observó una alta concentración de casos con alta proporción de soja de primera en la cercanía a los puertos. Es de destacar que entre los puertos de Rosario, San Lorenzo y San Martín en Santa Fe, se transporta más del 65 % de los granos exportados de Argentina (MINAGRI 2022a). A su vez también es alta la concentración de industrias manufactureras de soja en esta provincia (Giancola et al. 2011). Si bien la disminución del costo de flete por la cercanía al puerto y centros de acopio puede ser una oportunidad para la siembra de soja, esto es aún exacerbado en casos de arrendamiento de tierras, donde la incidencia proporcional del flete en el margen bruto es mayor, dado que se debe descontar el costo del arrendamiento (Calzada y Corina 2017).

En esta región del sur de Santa Fé se señala también que el tamaño de las explotaciones es relativamente pequeño y es baja la proporción de propietarios que viven en el campo, a comparación con otras regiones pampeanas (Mikkelsen et al. 2008). En relación a lo analizado en el capítulo 2 en parte de la zona núcleo, es esperable una alta frecuencia de casos de monocultivo de soja en parcelas catastrales pequeñas comúnmente asociadas a tierras arrendadas (Pengue 2005; Haro Sly 2017). La existencia de tierras arrendadas y cercanas a puertos o centros de industrialización, pudo haber generado la alta concentración del monocultivo de soja en parte de estas regiones.

Los últimos Censos Nacionales Agropecuarios de Argentina (1998, 2002 y 2018) muestran una disminución del número de explotaciones más pequeñas y un aumento del área ocupada por explotaciones grandes (García 2020), indicando procesos de expulsión de productores más pequeños y concentración de tierras. También se observa a lo largo de los censos un incremento en el porcentaje de tierras arrendadas, representando en el año 2018 más del 30 % del área en las provincias de Córdoba, Santa Fé, Buenos Aires y Entre Ríos (García 2020). Los procesos de expulsión pueden ser indicadores de situaciones donde no se alcanza el tamaño de unidad económica para la producción, favoreciendo la implementación de cultivos de flujo de dinero rápido y menor requerimiento de escala como la soja de primera (Bert et al. 2011), y favoreciendo la adopción de contratos de arrendamiento a corto plazo. Es posible entonces que las condiciones registradas asociadas con la expulsión de productores más pequeños y la alta proporción de tierras arrendadas favorezcan la alta frecuencia de soja en sectores de la región pampeana.

Otro índice que mostró similitud con una variable espacialmente explícita fue la intensidad de siembra (número de cultivos por año). La comparación de los mapas de distribución del número de cultivos por año y precipitación media anual mostraron

algunos patrones similares. Esto pone en evidencia las limitaciones que existen en algunas zonas a la intensificación mediada por la dificultad de siembra de cultivos de invierno (e.g. oeste de Córdoba) y/o dobles cultivos (e.g. sudoeste de Buenos Aires). Además de limitar las posibilidades de rotación (no permitiendo incluir por ejemplo un cultivo de invierno en una secuencia de cultivos de verano), esto implica que en sistemas de agricultura continua, gran parte del año el suelo se encuentre sin cobertura vegetal verde, volviéndose muy relevante la disponibilidad y el tipo de rastrojos, definida por el cultivo antecesor y el manejo que se haga de los mismos. Por otro lado, se observó también que la disponibilidad de precipitaciones no es el único factor que define la intensidad de siembra (más precipitaciones no implica que siempre se siembren más cultivos por año), sino que en zonas donde la precipitación ya no es limitante, factores humanos como los mencionados anteriormente (distancia a puertos y centros de industrialización, propiedad de la tierra, etc.) juegan un rol importante.

La falta de asociación entre los casos de una única especie sembrada durante las tres campañas consideradas con la precipitación, podría indicar que el monocultivo es afectado más preponderantemente por factores humanos que ambientales. Con excepción de la caña de azúcar que se realiza en zonas con elevada precipitación (e.g. Tucumán), otros casos de monocultivo como el de soja estarían fuertemente influenciados por aspectos económicos y de tenencia de la tierra. La siembra de tres especies durante las tres campañas consideradas mostró una relación positiva con la precipitación. A su vez, también la relación positiva entre intensidad de siembra y precipitación, podría reflejar que los esquemas de rotación estén limitados por las condiciones ambientales presentes del sitio.

5.5. Conclusiones

En este capítulo se presentaron diversos índices de rotación propuestos a lo largo de esta tesis que fueron aplicados a una escala nacional. Esto permitió identificar situaciones de potencial riesgo de daño de los sistemas agrícolas, que podrían afectar el crecimiento y rendimiento de los cultivos en el corto plazo y generar condiciones irreversibles en el ambiente de cultivo a largo plazo. Se identificó un sector asociado a condiciones más áridas donde no es frecuente la realización de cultivos de invierno o más de un cultivo por año. Esto último implica la imposibilidad de incrementar el área sembrada, por efecto de un segundo cultivo en la campaña, en un sector relevante del área agrícola argentina. También, en la medida que en estas zonas se utilicen sistemas de agricultura continua, existirá una alta exposición del suelo en el período del año sin cultivo en estos casos, y una menor capacidad de intercepción de radiación que podría afectar la incorporación de carbono al sistema o generar procesos de erosión.

En algunos sectores como la zona núcleo agrícola, con alto potencial de cultivo y sin limitantes de precipitaciones, se observó una alta concentración de casos con alta proporción de soja de primera, esta vez asociado a la cercanía a puertos y centros de industrialización de soja, y posiblemente a lotes con alta frecuencia de arrendamiento también presentes en esta región. De esta manera vuelve a plantearse la hipótesis y predicción de la sección 1.2 acerca de la mayor probabilidad de ocurrencia de casos de monocultivo de soja en lotes arrendados, y en particular cuando el margen bruto de un cultivo sobre otro genera un incentivo adicional, al considerar por ejemplo diferencias en el valor del flete. La bibliografía muestra información contrastante en cuanto a la rentabilidad de sistemas de producción de maíz o soja de primera, dependiendo del sitio de estudio y el período de tiempo considerado (Bert et al. 2011; Videla Mensegue et al. 2022). Sin embargo, la relación observada entre el área sembrada anualmente con soja y

su precio internacional (sección 2.3.1), indicarían que el margen económico influye también en la decisión de qué cultivo sembrar, pudiendo generar dominancia sobre el resto de los cultivos de la rotación.

La riqueza de especies analizada a escala nacional presentó parcialmente una respuesta a las condiciones del ambiente, al ubicarse mayormente los casos con tres cultivos diferentes en las regiones con mayores niveles de precipitación. Se puede inferir que existen limitantes ambientales para la definir la riqueza de especies cultivadas en la rotación a partir de la fuerte asociación observada entre intensidad de siembra y precipitación media anual. Intensidades de siembra bajas implican en general la siembra únicamente de cultivos de verano (e.g. oeste de Córdoba) o la siembra únicamente de cultivos de invierno (e.g. sudoeste de Buenos Aires).

Capítulo VI

Conclusiones Generales

6.1. Aspectos generales

6.1.1. Principales logros de la tesis

Esta tesis permitió desarrollar metodologías y generar información para caracterizar y cuantificar las rotaciones y su impacto en el crecimiento de cultivos y el carbono del suelo, siendo algunos análisis a escala regional y otros a escala nacional. En Argentina, la disponibilidad de información con suficiente detalle espacial (que permita identificar lotes de cultivo o unidades de manejo) y de leyenda (que diferencie tipos de cultivo) y con continuidad temporal (que permita identificar secuencias de cultivos) era muy escasa al inicio de esta tesis. Sólo en los últimos años (campañas 2018/2019 a 2020/2021) se comenzó a generar información de este tipo cubriendo las principales regiones agrícolas de Argentina a través del Mapa Nacional de Cultivos (de Abelleira et al. 2019; de Abelleira et al. 2020b; de Abelleira et al. 2021). Previo a esto, sólo existía información dispersa sobre la distribución de cultivos en cuanto a regiones y temporalidad, o la disponible a nivel departamento. Sería muy conveniente dar continuidad a la generación de mapas de cultivos a escala nacional para realizar análisis de secuencias de cultivos a más largo plazo, como los realizados en los primeros capítulos de esta tesis que incluyeron una descripción de lo ocurrido a lo largo de siete campañas agrícolas.

Como se describió en el segundo capítulo, en esta tesis se generaron mapas anuales de tipo de cultivo en una zona piloto de la Pampa Ondulada durante siete campañas consecutivas (2010/2011 a 2016/2017). La resolución espacial utilizada (30 metros) permitió describir y analizar las secuencias de cultivos ocurridas a nivel de lote y su relación con variables ambientales y humanas. Los resultados mostraron cómo situaciones más frecuentes a la alternancia de períodos cortos de rotación y de

monocultivo de soja. También es de destacar que en algunos sectores mapeados se observaron casos tanto de monocultivo de soja como de rotación durante todo el período considerado. Se identificó la influencia de factores humanos en la determinación de las decisiones de siembra. Se observó una gran influencia del tamaño de parcela catastral, que está asociado al grado de capitalización del productor y a la ocurrencia de arrendamiento, en la presencia de casos de monocultivo de soja y de la rotación maíz, soja, trigo-soja. Al estar asociado el tamaño de parcela catastral a la frecuencia de arrendamientos, se puede inferir que el tipo de tenencia de la tierra también afecta la decisión de la secuencia de siembra.

En el tercer capítulo se generó un modelo de estimación de biomasa de soja utilizando información satelital proveniente de sensores de RADAR y ópticos. El mismo fue generado y validado a partir de mediciones a campo en la Pampa Ondulada. Previo a la generación se analizó la respuesta de variables medidas a campo frente a diversas bandas e índices derivados de plataformas satelitales. Se observó una alta respuesta a variables con una gran dinámica temporal como biomasa fresca y la fracción de radiación interceptada. Las capas de información satelital que mejor ajuste obtuvieron fueron la polarización HV en RADAR en banda C (RADARSAT 2) y la reflectancia en rojo en sensores ópticos, mostrando la primera un mejor ajuste a lo largo de todo el ciclo del cultivo. Se observaron valores muy estables del contenido de agua de la vegetación (porcentaje de agua sobre la biomasa seca) durante la etapa inicial del ciclo del cultivo (previo al momento de máximo IVN). La disminución en la humedad vegetal durante la parte final del ciclo pudo ser predicha a partir del índice de vegetación derivado de sensores ópticos. El modelo de biomasa propuesto implicó la estimación de la biomasa fresca a partir de información de RADAR en banda C y del

contenido de humedad a partir del IVN, para finalmente obtener la biomasa seca de cultivos de soja.

Los resultados mostraron la capacidad de sistemas de RADAR en banda C para describir aspectos de la vegetación a lo largo de los diferentes momentos del ciclo del cultivo de soja. La gran asociación de la retrodispersión de RADAR en esta longitud de onda con la biomasa húmeda, permitirá caracterizar el estado de los cultivos en diversos momentos del ciclo de cultivos de soja bajo los sistemas de producción de la Pampa Ondulada (e.g. en siembra directa). A su vez, la combinación con modelos que predigan independientemente el contenido de humedad, permitió caracterizar la biomasa seca, un componente principal del rendimiento del cultivo.

En el cuarto capítulo, se implementó el modelo de biomasa generado previamente sobre una serie de escenas de RADAR (plataforma RADARSAT 2) e imágenes ópticas (Sentinel 2 y Landsat 8) obtenidas a lo largo de la campaña 2018/2019 en el sitio piloto de la Pampa Ondulada. Esta herramienta permitió analizar el impacto de diversos índices de rotación, derivados de los mapas de secuencias de cultivos generados en el segundo capítulo, sobre el crecimiento de cultivos de soja. Se obtuvo así información para evaluar 1153 lotes de soja de primera y 743 de soja de segunda. Los resultados mostraron un efecto marcado de los índices de rotación sobre la biomasa seca en lotes de soja de primera, con efectos significativos en casi todas las fechas analizadas. En soja de primera se identificó una respuesta positiva y significativa en el crecimiento en biomasa seca al número de períodos con rotación recomendada y a la proporción de gramíneas en la rotación; mientras que se observó una respuesta negativa y significativa en biomasa seca para el número de períodos con monocultivo de soja y para la proporción de soja de primera en la secuencia. La respuesta en biomasa en soja de segunda fue de menor magnitud, mostrando efectos significativos solo en una de las

fechas analizadas. Se analizó también la respuesta de los índices mencionados al carbono del suelo utilizando mediciones realizadas al final de la campaña 2018/2019, pero no se encontraron efectos significativos de los índices de rotación, con excepción de la intensidad de siembra, que mostró una relación negativa con los valores de carbono del suelo.

La disponibilidad de información de mapas de cultivos a escala nacional (obtenidos durante tres campañas: 2018/2019 a 2020/2021), permitió generar índices de rotación propuestos a lo largo de esta tesis sobre una extensión más grande y ampliar el análisis del efecto de variables ambientales como la precipitación y humanas como la distancia a puertos sobre las decisiones de siembra. El análisis realizado en el capítulo V mostró algunas limitantes a la intensidad de siembra y variabilidad de cultivos sembrados por lote, que estuvieron asociadas a los valores de precipitación media anual registrados durante las tres campañas analizadas. No se observaron prácticamente casos con más de un cultivo por año con precipitaciones menores a 600 mm anuales. A partir de 600 mm se comenzaron a observar casos con dos cultivos durante al menos una campaña, y a partir de 700 mm, comienza a aparecer el doble cultivo durante dos de tres campañas. Es de destacar también que los casos con un solo cultivo por año también fueron frecuentes con niveles de precipitación de hasta 1000 mm, sugiriendo en estos casos, la existencia de otros factores diferentes a la precipitación que definen las decisiones de siembra. Por encima de 1000 mm, los casos de un cultivo por año caen abruptamente, asociado esto con posibles excesos de humedad del suelo con la siembra de un único cultivo por año.

La ubicación de casos con monocultivo de soja (un caso particular de un cultivo por año) o con alta frecuencia de soja de primera en la rotación mostró un patrón de concentración en un sector de la zona núcleo agrícola, con cercanía a los principales

puertos y centros de industrialización de granos. Este patrón podría reflejar la oportunidad de obtener márgenes brutos más altos con la disminución de costos de transporte, aspecto que es aún más beneficioso en casos de arrendamiento en que el costo del flete es proporcionalmente mayor. En campos alquilados, el margen bruto es menor por el costo del alquiler, provocando así que la incidencia de otros costos como el transporte sea mayor. Calzada y Corina (2017) señalan incrementos de hasta tres veces en la incidencia del flete en el margen bruto de campos alquilados frente a campos propios.

Como se concluyó anteriormente, los casos de monocultivo de soja también estuvieron asociados a parcelas catastrales más pequeñas, más propensas al arrendamiento con baja capacidad de negociación de contratos. Es así que la combinación de estos dos factores humanos (situaciones de arrendamiento y bajo costo de flete por cercanía a centros de acopio), podría ser la principal causa de la distribución espacial de casos de monocultivo de soja. Esto genera un riesgo de degradación potencial en una de las zonas más productivas, pudiendo afectar la sostenibilidad de estos sistemas de importancia estratégica para el país dado su gran aporte de divisas externas.

6.1.2. Contrastación de hipótesis planteadas

En esta sección se presentan las hipótesis planteadas en el capítulo introductorio (sección 1.2) y se evalúa su validez luego de los resultados obtenidos de esta tesis.

Con respecto a la primera hipótesis y sus predicciones, es difícil asociar directamente el número de especies sembradas a factores o limitaciones ambientales. A escala nacional se identificó que la precipitación restringió la diversidad de especies, observándose más de tres especies en un período de tres campañas solamente en sitios

con niveles de precipitación intermedio y alto. El análisis de la intensidad de siembra permite inferir que en situaciones con único cultivo por año existen restricciones de la precipitación a la siembra de un cultivo invernal o a la siembra de doble cultivo en una campaña. De esta manera se concluye que existe una limitante al número de especies en planteos de rotación en zonas con bajo nivel de precipitaciones. En el análisis en Pampa Ondulada, los casos con alta frecuencia de rotación con 3 cultivos (rotación de maíz, soja de primera y trigo / soja), mostraron asociación con suelos de baja productividad (capacidad de uso más alta), no mostrando una limitación ambiental a partir de este análisis.

La dominancia de una especie en la secuencia de cultivos (como en los casos de monocultivo) mostró una clara asociación a factores humanos. En el área piloto ubicada en Pampa Ondulada, los casos de monocultivo de soja (dominancia de una especie) fueron más frecuentes en parcelas catastrales chicas, comúnmente asociadas a situaciones de arrendamiento y con escasa capacidad de negociación de estos contratos. Cabe mencionar que casos de monocultivo de soja también estuvieron asociados a factores ambientales ya que fueron más frecuentes en suelos de mejores condiciones (mayor elevación y más baja capacidad de uso). A nivel nacional, los casos de mayor proporción de soja de primera estuvieron asociados a la cercanía a puertos y plantas de industrialización, relacionado esto a mayores márgenes brutos por disminución de costos de transporte. En las zonas en que se encontró alta frecuencia de soja de primera también es esperable que exista una alta frecuencia de arrendamiento, debido a que allí el tamaño de las explotaciones es relativamente pequeño (Mikkelsen et al. 2008), lo que podría hacer más relevante el costo del transporte en el margen bruto, al considerar el arrendamiento como costo adicional. Sin embargo, se encontró gran discrepancia en la literatura sobre si la rentabilidad es mayor entre cultivos de maíz o de soja, siendo esta

dependiente del sitio y el momento considerado. Los resultados obtenidos en la sección 2.2.1 muestran una relación entre el área sembrada con soja y su precio internacional, con lo que se puede inferir un efecto del margen económico en la decisión de siembra.

Con respecto a la segunda hipótesis, se asume que existen mecanismos de transmisión de información y recursos a largo plazo en los sistemas de producción agrícola de la Pampa Ondulada que utilizan un bajo nivel de insumos, respondiendo en cultivos de soja de primera a situaciones ocurridas a lo largo de siete campañas agrícolas, incluyendo múltiples situaciones ambientales y de manejo. En estos sistemas, donde es poco frecuente la fertilización nitrogenada (Satorre 2011; Novelli et al. 2023), se observó un efecto importante de la secuencia de cultivos, medida a través de diversos índices de rotación en el crecimiento de cultivos medido en biomasa en una campaña específica, incluso en comparación con otras variables ambientales consideradas.

Con respecto a la tercera hipótesis y sus predicciones, los resultados no mostraron una disminución del carbono orgánico del suelo en casos con alta proporción de soja de primera. Sin embargo, al observarse un efecto de las secuencias de cultivos sobre la biomasa de soja, puede inferirse que se pueden haber afectado otras propiedades del suelo como por ejemplo la capacidad de retención hídrica que no está definida solamente por el nivel total de carbono en el suelo, sino que se suman otros aspectos como la distribución de tamaños de agregados en el suelo, su estabilidad, etc. En consecuencia, es necesario evaluar a futuro el efecto de las distintas secuencias de cultivos sobre otras variables que describan las propiedades físicas de los suelos. Es posible también, que el número de muestras de suelo disponibles no sea el adecuado para caracterizar las múltiples situaciones de manejo del área de estudio (que a su vez se desconocen, más allá de conocer la secuencia de cultivos). Pueden existir situaciones particulares de manejo en algunos sitios muestreados que tengan algún efecto

dominante en el resultado del análisis. Sería conveniente incorporar una mayor cantidad de variables físicas a medir en el marco Observatorio Nacional de Suelos Agropecuarios (ONSA 2023).

6.1.3. Implicancias para el manejo sostenible de los recursos naturales

A lo largo de esta tesis se generó información que permitió caracterizar secuencias de cultivos a diferentes escalas, un aspecto que requiere un detalle de lo que ocurre a nivel de lote y con continuidad en el tiempo, aspecto que no había sido resuelto hasta hace unos años atrás. Esto permitió caracterizar la ocurrencia del grado de rotación o de monocultivo a partir de información precisa y objetiva, evitando generalizaciones con escasa fundamentación. La caracterización espacial de las secuencias de cultivos permitió también analizarla en relación a otras variables espacialmente explícitas, identificando algunas causas de la distribución espacial de casos de monocultivo o rotación y conocer su impacto en el crecimiento de cultivos y en el carbono orgánico del suelo.

Caracterizar en detalle en que sitios ocurren casos de buenas o malas prácticas agrícolas relacionadas con la planificación de la historia de siembra, el impacto que generan y sus posibles causas, permitirá entre otras cosas:

- Conocer el estado actual de los sistemas agropecuarios
- En la medida que intervengan causas humanas, generar condiciones que incentiven la realización de buenas prácticas para lograr sistemas más sustentables.

Las propuestas que incentiven la realización de rotaciones podrían incluir:

- Regulación de los arrendamientos agrícolas, definiendo plazos mínimos mayores a un año y que aseguren algún grado de rotación.
- Brindar incentivos a la rotación de cultivos o a la siembra de más de un cultivo por año, por ejemplo mediante exenciones impositivas.
- Favorecer el uso de transportes más económicos como el ferrocarril que no sean tan dependientes de la distancia a los centros de acopio.
- Planificar la logística de transporte y de localización de plantas industriales de forma más espaciada, por ejemplo mediante la promoción industrial en determinados sitios, permitiría evitar una gran concentración de casos de monocultivo.

6.2. Avances logrados en el conocimiento

En el marco de la red JECAM, se realizó una gran cantidad de toma de muestras y mediciones a campo, procesamiento en laboratorio, y recorridos por rutas y caminos con registro de puntos GPS a lo largo de varios años sobre un sitio piloto en los alrededores de San Antonio de Areco. A su vez, la pertenencia a la red facilitó la captura de imágenes satelitales no disponibles libremente como las imágenes de RADAR RADARSAT 2 y TerraSAR-X, y ópticas como Resourcesat y AWIFS, que complementaron la falta de imágenes disponibles durante un período, como fue lo ocurrido con el cese de funcionamiento del satélite Landsat 5 en 2011.

La realización con éxito de mapas secuenciales de tipo de cultivos, por medio de relevamientos sobre vehículos realizadas en el sitio piloto mencionado y en otros sitios de la red JECAM de otros países, así como la generación de protocolos de relevamiento a campo y de definición de clases, fueron la base para la expansión de los mapas de cultivos a una escala mayor pero con el mismo detalle espacial. Esto dio lugar a la

generación de mapas de cultivos cubriendo las principales regiones agrícolas de Argentina, que se comenzaron a llevar a cabo en forma secuencial desde 2018 (de Abelleira et al. 2019; de Abelleira et al. 2020b; de Abelleira et al. 2021).

La generación de nueva información a nivel de lote (nivel al que ocurre la rotación o el monocultivo) de secuencias de cultivo obtenidas a partir de mapas de cultivos de campañas consecutivas como los que se generaron en esta tesis y a través del Mapa Nacional de Cultivos del INTA, es lo que permite identificar en forma objetiva la ocurrencia de monocultivo o rotación y cuantificar su magnitud de ocurrencia y distribución espacial tanto a nivel regional como nacional. La generación de información de base, es relevante porque da pie a la realización de diversos análisis posteriores como son la caracterización de la ocurrencia de monocultivo o rotación y su impacto como los descriptos en esta tesis. Sería posible entonces, analizar las secuencias de cultivos observadas en Argentina durante una serie de años consecutivos en relación a numerosas capas de información espacialmente explícita que estén disponibles (e.g. diversidad de aves, de insectos, distribución de centros de industrialización y logística, redes de transporte, etc.).

El análisis de información de RADAR permitió identificar que una plataforma en banda C como RADARSAT 2 es muy adecuada para la caracterización del crecimiento y rendimiento de cultivos como la soja, el principal cultivo de la Argentina, bajo sistemas de siembra directa. En particular, la fuerte relación observada entre la humedad vegetal en soja y la retrodispersión de RADAR en banda C, habilita el uso de esta tecnología para la identificación de situaciones de stress hídrico. También las diferencias observadas en la respuesta del RADAR a la humedad en el fin de ciclo, permitiría identificar el grado de avance en la madurez de los granos de soja. Esto es de relevancia en el marco reciente lanzamiento de la misión SAOCOM (Constelación

satelital argentina de RADAR en banda L) que se encuentra actualmente en órbita y en plena etapa operativa. Dada la corta vida útil de los satélites, es imperioso incrementar la investigación sobre el uso de imágenes de RADAR de esta longitud de onda (banda L), en particular para la caracterización de socioecosistemas de Argentina.

6.3. Líneas emergentes de investigación

Este trabajo demuestra la importancia de la generación de información básica detallada y de gran extensión para la caracterización de aspectos que describen la sustentabilidad de los sistemas agrícolas. Es estratégico para el país dar continuidad a iniciativas de generación de información y mapeo a escala nacional con alto grado de detalle. Esto permitirá disponer de series largas de secuencias de cultivos y analizarlas en relación a numerosas fuentes de información (nuevos mapas, mediciones y registros georeferenciados).

En esta tesis se generó información muy promisoriosa que permite la estimación de biomasa en cultivos de soja a partir de imágenes de RADAR. Se identificó la necesidad de realizar una calibración en cada campaña para ajustar los valores de biomasa para avanzar en la generación de un sistema operativo de estimación de rendimiento. La modelación del índice de cosecha en función de variables ambientales y/o de crecimiento de los cultivos permitirá convertir las estimaciones en valores de rendimiento. Se observa también la necesidad de ampliar estos estudios sobre otros cultivos como maíz, trigo y girasol, y evaluar la respuesta de RADAR en otras longitudes de onda como la banda L que presenta el satélite argentino SAOCOM, actualmente en órbita. Esto requerirá un gran esfuerzo en relación a la realización de

mediciones a campo que permitan generar modelos y validarlos a partir de la información satelital utilizada.

En este trabajo se consideraron índices relativamente sencillos para describir secuencias de cultivos, cuantificando el número o proporción de diferentes cultivos durante un período de tiempo. Sin embargo, es posible una caracterización más detallada incluyendo el tiempo de ocupación de cada cultivo considerado (e.g. Videla Mensegue et al. 2022). Es más, el tiempo de ocupación podría ser estimado utilizando tecnología satelital para considerar la variabilidad intraespecífica en duración del ciclo o para considerar diferencias en el desarrollo según las condiciones ambientales.

REFERENCIAS

7. Referencias

- Acuña, M.A., Ferrazzoli, P., Guerriero, L. 2019. Modeling L- and X-band backscattering of wheat and tests over fields of Pampas. *European Journal of Remote Sensing*, 52: 84-101.
- Andriulo, A., Guérif J., Mary, B. 1999. Evolution of soil carbon with various cropping sequences on the rolling pampas. Determination of carbon origin using variations in natural ^{13}C abundance. *Agronomie*, 19: 349-364.
- Aramburu Merlos, F., Monzón, J.P., Mercau, J.L., Taboada, M., Andrade, F.H., Hall, A.J., Jobbagy, E., Cassman, K.G., Grassini, P. 2015. Potential for Crop Production Increase in Argentina through Closure of Existing Yield Gaps. *Field Crops Research*, 184:145-154.
- Arbeletche, P., Ernst, O., Hoffman, E. 2010. La agricultura en Uruguay y su Evolución. Pp. 13-28 en García Préchac, F., Ernst O., Arbeletche, P., Pérez Bidegain, M., Pritsch, C., Ferenczi, A., Rivas, M. (eds.) Intensificación agraria oportunidades y amenazas para un país productivo y natural. CSIC, Montevideo, Uruguay.
- Aschbacher, J. 2017. ESA's earth observation strategy and Copernicus. Pp. 81-86 en Onoda, M., Young, O.R. (eds.) Satellite earth observations and their impact on society and policy. Springer, Singapur.
- Attema, E.P.W., Ulaby, F.T. 1978. Vegetation modeled as a water cloud. *Radio Science*, 13: 357-364.
- Baddeley, A., Turner, R. 2005. Spatstat: an R package for analysing spatial point patterns. *Journal of Statistical Software*, 12: 1-42.

Baeza, S., Vélez-Martin, E., de Abelleira, D., Banchemo, S, Gallego, Schirmbeck, J., Veron, S., Vallejos, M., Weber, E., Oyarzabal, M., Barbieri, A., Petek, M., Guerra Lara, M., Sarrailhe, S., Baldi, G., Bagnato, C., Bruzzone, L., Ramos, S., Hasenack, H. 2022. Two decades of land cover mapping in the Río de la Plata grassland region: The MapBiomass Pampa initiative. *Remote Sensing Applications: Society and Environment*, 28: 100834.

Baghdadi, N., El Hajj, M., Zribi, M., Bousbih, S. 2017 Calibration of the water cloud model at C-Band for winter crop fields and grasslands. *Remote Sensing*, 9: 969.

Bai, X., He, B., Li, X., Zeng, J., Wang, X., Wang, Z., Zeng, Y., Su, Z. 2017. First assessment of Sentinel-1A data for surface soil moisture estimations using a coupled water cloud model and advanced integral equation model over the Tibetan Plateau. *Remote Sensing*, 9: 714.

Balsa, J. 2001. Las formas de producción predominantes en la agricultura pampeana al final de la primera expansión agrícola (1937): ¿Una vía "argentina" de desarrollo del capitalismo en el agro?. *Mundo Agrario*, 2.

Barraco, M., Lardone, A., Girón, P., Díaz-Zorita, M. 2017. Secuencias agrícolas en suelos representativos del Noroeste Bonaerense. Pp. 199-218 en Salvaggiotti F, Krüger H, Studdert G. (eds.) *Ensayos de larga duración en Argentina: un aporte al logro de sistemas agrícolas sustentables*. Ediciones INTA, Entre Ríos, Argentina.

Barros, V., Vera, C., Agosta E., Araneo, D., Camilloni, I., Carril, A., Doyle, M., Frumento, O., Nuñez, M., Zárate, M., Penalba, O., Rusticucci, M., Saulo, C., Solman, S. 2015. Tercera Comunicación Nacional de la República Argentina a la Convención

Marco de las Naciones Unidas sobre Cambio Climático. Jefatura de Gabinete de Ministros. Presidencia de la Nación, Buenos Aires, Argentina (2015), 341 p.

Beale, J., Snapir, B., Waine, T., Evans, J., Corstanje, R. 2019. The significance of soil properties to the estimation of soil moisture from C-band synthetic aperture radar. *Hydrology and Earth System Sciences Discussions*, 1-32.

Becker-Reshef, I., Vermote, E., Lindeman, M., Justice, C. 2010. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114: 1312-1323.

Bégué, A., Arvor, D., Bellon, B., Betbeder, J., de Aballeyra, D., Ferraz, R., Lebourgeois, V., Lelong, C., Simões, M., Verón, S. 2018. Remote sensing and cropping practices: A review. *Remote Sensing*, 10: 99.

Bert, F.E., Podestá, G.P., Rovere, S.L., Menéndez, Á.N., North, M., Tatara, E., Laciana, C.E., Weber, E., Toranzo, F.R. 2011. An agent based model to simulate structural and land use changes in agricultural systems of the argentine pampas. *Ecological Modelling*, 222, 3486-3499.

Bolsa de Cereales de Buenos Aires. 2019. Panorama Agrícola Semanal. Departamento de Estimaciones Agrícolas. Newsletter, Bolsa de Cereales de Buenos Aires.

<<http://www.bolsadecereales.com/ver-acerca-del-panorama-agricola-semanal-78#>>
(Acceso: 27/08/2019).

Bolsa de Cereales de Buenos Aires. 2023. Guía Metodológica de Estimaciones Agrícolas. Departamento de Estimaciones Agrícolas. Bolsa de Cereales de Buenos

Aires. <<https://www.bolsadecereales.com/imagenes/GuiaPASyECC.pdf>> (Acceso: 01/03/2023).

Bontemps, S., Defourny, P., van Bogaert, E., Arino, O., Kalogirou, V., Ramos-Perez, J. 2011. GlobCover 2009. Products Description and Validation Report. ESA, Paris, Francia.

Bouët, A., Laborde Debucquet, D. 2016. Food Crisis and Export Taxation: Revisiting the Adverse Effects of Non cooperative Aspect of Trade Policies. Pp. 167-179 en Kalkuhl, M., von Braun, J., Torero, M. (eds.) Food Price Volatility and Its Implications for Food Security and Policy. Springer, Cham, Suiza.

Calviño, P.A., Sadras, V.O., Andrade, F.H. 2003. Quantification of environmental and management effects on the yield of late-sown soybean. *Field Crops Research*, 83: 67-77.

Calzada, J., Corina, S. 2017. Los costos del flete sobre los márgenes del productor de soja. Bolsa de Comercio de Rosario. Informativo Semanal Octubre 2017. <<https://www.bcr.com.ar/es/mercados/investigacion-y-desarrollo/informativo-semanal/noticias-informativo-semanal/los-costos-del>> (Acceso: 10/06/2022).

Campbell, C.A. 1978. Soil organic carbon, nitrogen and fertility. Pp. 173-271 en Schnitzer, M. y Khan S.U. (eds.) Developments in soil science. Elsevier, Amsterdam, Países Bajos.

Canisius, F., Shang, J., Liu, J., Huang, X., Ma, B., Jiao, X., Geng, X., Kovacs, J.M., Walters, D. 2018. Tracking crop phenological development using multi-temporal polarimetric Radarsat-2 data. *Remote Sensing of Environment*, 210: 508-518.

Caride, C., Paruelo, J.M. 2007. Discriminación del sistema de labranza mediante el uso de imágenes Landsat en el Norte de Buenos Aires. Pp. 179-184 en TELEDETECCIÓN - Hacia un mejor entendimiento de la dinámica global y regional. Ed. Martin, 2007, ISBN: 978-987-543-126-3.

Carpenter, S.R. 2002. Ecological futures: building an ecology of the long now. *Ecology*, 83: 2069-2083.

Chander, G., Markham, B. L., Helder, D. L. 2009. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113: 893-903.

Chapin III F.S., Folke C., Kofinas G.P. 2009. A framework for understanding change. Pp. 3-28 en Folke, C., Kofinas, G., Chapin, F. (eds.) Principles of ecosystem stewardship, Springer, New York, EE.UU.

Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng S., Lu, M., Zhang, W., Tong, X., Mills, J., 2015. Global Land Cover Mapping at 30 m Resolution: A POK-Based Operational Approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103: 7-27.

D'Acunto, L., Semmartin, M., Ghersa, C.M. 2016. Uncultivated margins are source of soil microbial diversity in an agricultural landscape. *Agriculture, Ecosystems & Environment*, 220: 1-7.

Daughtry, C.S.T., Gallo, K.P., Goward, S.N., Prince, S.D., Kustas, W.P. 1992. Spectral estimates of absorbed radiation and phytomass production in corn and soybean canopies. *Remote Sensing of Environment*, 39: 141-152.

de Abelleyra, D., Banchemo, S., Verón, S., Mosciaro, J., Volante, J. 2019. Mapa Nacional de Cultivos campaña 2018/2019. Colección 1. Versión 1. Informe. Instituto Nacional de Tecnología Agropecuaria (INTA), Argentina.

<https://inta.gob.ar/sites/default/files/mapa_nacional_de_cultivos_campana_2018_2019.pdf> (Acceso: 10/01/2022).

de Abelleyra, D., Verón, S.R. 2014. Comparison of different BRDF correction methods to generate daily normalized MODIS 250m time series. *Remote Sensing of Environment*, 140: 46-59.

de Abelleyra, D., Veron, S., Banchemo, S., Mosciaro, M. J., Propato, T., Ferraina, A.,..., Volante, J. 2020a. First large extent and high resolution cropland and crop type map of Argentina. Pp 392-396 en 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS). IEEE.

de Abelleyra, D., Veron, S., Banchemo, S., Mosciaro, J.,..., Volante J. 2020b. Mapa Nacional de Cultivos campaña 2019/2020. Colección 1. Versión 1.0. Informe. Instituto Nacional de Tecnología Agropecuaria (INTA), Argentina.

<https://inta.gob.ar/sites/default/files/mapa_nacional_de_cultivos_2019_2020_v1.pdf> (Acceso: 10/01/2022).

de Abelleyra, D., Verón, S., Banchemo, S., Iturrealde Elortegui, M., Valiente S.,..., Volante J. 2021. Mapa Nacional de Cultivos campaña 2020/2021. Colección 1. Versión 1.0. Informe. Instituto Nacional de Tecnología Agropecuaria (INTA), Buenos Aires, Argentina.

<https://inta.gob.ar/sites/default/files/informe_mapa_nacional_de_cultivos_campana_2020_2021_0.pdf> (Acceso: 10/01/2022).

- De la Casa, A., Ovando, G., Bressanini, L., Martínez, J., Díaz, G., Miranda, C. 2018. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146: 531-547.
- Deschamps, B., Mc Nairn, H., Shang, J., Jiao, X. 2012. Towards operational radar-only crop type classification: comparison of a traditional decision tree with a random forest classifier. *Canadian Journal of Remote Sensing*, 38: 60-68.
- Didan, K. 2015. MOD13Q1 MODIS/Terra Vegetation Indices 16-Day L3 Global 250m SIN Grid V006 [Data set]. NASA EOSDIS Land Processes DAAC. <<https://doi.org/10.5067/MODIS/MOD13Q1.006>> (Acceso: 1/3/2023).
- Djenderedjian, J. 2008. La agricultura pampeana en la primera mitad del siglo XIX. Buenos Aires: Siglo XXI Editores, Buenos Aires, Argentina.
- Dong, T., Liu, J., Qian, B., He, L., Liu, J., Wang, R., Shang, J. 2020. Estimating crop biomass using leaf area index derived from Landsat 8 and Sentinel-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168: 236-250.
- Dury J., Schaller N., Garcia F., Reynaud A., Bergez J.E. 2012. Models to support cropping plan and crop rotation decisions. A review. *Agronomy for Sustainable Development*, 32: 567-580.
- Duval, M.E., Capurro, J.E., Galantini, J.A., Andriani, J.M. 2015. Utilización de cultivos de cobertura en monocultivo de soja: efectos sobre el balance hídrico y orgánico. *Ciencia del Suelo*, 33: 247-261.

ESA. 2023. ESA Sentinel Application Platform. Agencia Espacial Europea.
<<http://step.esa.int>> (Acceso: 1/3/2023).

FAOSTAT. 2018. Comercio. Organización de las Naciones Unidas para la Alimentación y la Agricultura. FAOSTAT <<http://www.fao.org/faostat/es/#data>> (Acceso: 01/03/2018).

FAOSTAT. 2021. Comercio. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <<http://www.fao.org/faostat/en/#data>> (Acceso: 12/1/2021).

Farr, T.G, Rosen, P.A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E. Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., Alsdorf, D. 2007. The Shuttle Radar Topography Mission. *Reviews of Geophysics* 45: RG2004.

Fernández, D.A. 2010. La Unidad Económica Agropecuaria. Discusiones y aplicaciones en el marco del proceso de concentración económica en curso. *Revista Interdisciplinaria de Estudios Agrarios*, 32: 29-56.

Ferrazzoli, P, Paloscia, S., Pampaloni, P. , Schiavon, G., Sigismondi, S. , Solimini, D. 1997. The potential of multifrequency polarimetric SAR in assessing agricultural and arboreous biomass. *IEEE Transactions on Geoscience and Remote Sensing*, 35: 5-17.

Foerster, S., Klaus, K., Foerster, M., Itzerott, S. 2012. Crop Type Mapping Using Spectral–Temporal Profiles and Phenological Information. *Computers and Electronics in Agriculture*, 89: 30-40.

- Fritz, S., See, L., McCallum, I., Schill, C., Obersteiner, M., van der Velde, M., Boettcher, H., Havlik, P., Achard, F. 2011. Highlighting continued uncertainty in global land cover maps to the user community. *Environmental Research Letters*, 6: 044005.
- García, M. 2020. Una mirada cuantitativa de la estructura agraria argentina a través de los Censos Nacionales Agropecuarios 1988, 2002 y 2018. *Red Sociales, Revista del Departamento de Ciencias Sociales*, 7: 63-84.
- Gastaldi, A., Prado, S.A., Arduini, J.A., Miralles, D.J. 2020. Optimizing wheat (*Triticum aestivum* L.) management under dry environments: A case study in the West Pampas of Argentina. *Agricultural Water Management*, 233: 106092.
- Gates, D.M. 1980. *Biophysical Ecology*. Springer Verlag, New York, EE.UU.
- Giancola S.I., Salvador M.L., Covacevich M.S., Iturrioz G.M. 2011. Análisis de la cadena de soja en Argentina. Ediciones INTA, Buenos Aires, Argentina.
<https://inta.gob.ar/sites/default/files/script-tmp-cadena_soja.pdf> (Acceso: 10/06/2022).
- Gitelson, A.A. 2019. Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: generic algorithm for maize and soybean. *Remote Sensing Letters*, 10: 283-291.
- Gitelson, A.A., Peng, Y., Huemmrich, K.F. 2014. Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250 m resolution data. *Remote Sensing of Environment*, 147: 108-120.

Glavan, M., Pintar, M., Urbanc, J. 2015. Spatial variation of crop rotations and their impacts on provisioning ecosystem services on the river Drava alluvial plain.

Sustainability of Water Quality and Ecology, 5: 31-48.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R. 2017.

Google Earth Engine: planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202: 18-27.

Graesser, J., Stanimirova, R., Tarrío, K., Copati, E.J., Volante, J.N., Verón, S.R.,

Banchero, S., Helena, H., de Abelleira, D., Friedl, M.A. 2022. Temporally-Consistent Annual Land Cover from Landsat Time Series in the Southern Cone of South America. *Remote Sensing*, 14: 4005.

Grizzonet, M., Michel, J., Poughon, V., Inglada, J., Savinaud, M., Cresson, R. 2017.

Orfeo ToolBox: open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2: 1-8.

Guerschman, J., Paruelo, J.M., Di Bella, C., Giallorenzi, M.C., Pacin, F. 2003. Land

Cover Classification in the Argentine Pampas Using Multi-Temporal Landsat TM Data. *International Journal of Remote Sensing*, 24: 3381-3402.

Haro Sly, M. J. 2017. The Argentine portion of the soybean commodity chain. *Palgrave*

Communications, 3: 1-11.

Hosseini, M., McNairn, H., Mitchell, S., Robertson, L. D., Davidson, A., Homayouni,

S. 2019. Synthetic aperture radar and optical satellite data for estimating the biomass of corn. *International Journal of Applied Earth Observation and Geoinformation*, 83:

101933.

IGN. 2023. Capas SIG. Instituto Geográfico Nacional.

<<https://www.ign.gov.ar/NuestrasActividades/InformacionGeoespacial/CapasSIG>>

(Acceso: 1/3/2023).

INTA. Instituto Nacional de Tecnología Agropecuaria. 2009. Cartas de suelos de la República Argentina – Provincia de Buenos Aires: Escala 1:50.000 [online]. Buenos Aires, Instituto de Suelos. <<http://anterior.inta.gov.ar/suelos/cartas/index.htm>> (Acceso: 10/27/2019).

INTA. Instituto Nacional de Tecnología Agropecuaria. 2012. Cobertura del suelo de la República Argentina. Año 2006-2007. <<http://inta.gov.ar/documentos/cobertura-del-suelo-de-la-republica-argentina.-ano-2006-2007-lccs-fao/>> (Acceso: 1/12/2017).

JECAM. 2023. Experimentos Conjuntos para la Identificación y Seguimiento de Cultivos. <<http://jecam.org/>> (Acceso: 1/3/2023).

Karlen, D.L., Hurley, E.G., Andrews, S.S., Cambardella, C.A., Meek, D.W., Duffy, M.D., Mallarino, A.P. 2006. Crop Rotation Effects on Soil Quality at Three Northern Corn/Soybean Belt Locations. *Agronomy Journal*, 98: 484-495.

Kim, Y., Jackson, T., Bindlish, R., Lee, H., Hong, S. 2013. Monitoring soybean growth using L-, C-, and X-band scatterometer data. *International Journal of Remote Sensing*, 34: 4069-4082.

King, L., Adusei, B., Stehman, S.V., Potapov, P.V., Song, X.P., Krylov, A., Di Bella, C., Loveland, T.R., Johnson, D.M., Hansen, M.C. 2017. A multi-resolution approach to national-scale cultivated area estimation of soybean. *Remote Sensing of Environment*, 195: 13-29.

- Kluger, D.M., Owen, A.B., Lobell, D.B. 2022. Combining randomized field experiments with observational satellite data to assess the benefits of crop rotations on yields. *Environmental Research Letters*, 17: 044066.
- Kroes, J.G., van Dam, J., Supit, I., de Abelleira, D., Verón, S., de Wit, A., Boogard, H., Angelini, M., Damiano, F., Groenendijk, P., Wesseling, J., Veldhuizeng, A. 2019. Agrohydrological analysis of groundwater recharge and land use changes in the Pampas of Argentina. *Agricultural Water Management*, 213: 843-857.
- Kross, A., McNairn, H., Lapen, D., Sunohara, M., Champagne, C. 2015. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *International Journal of Applied Earth Observation and Geoinformation*, 34: 235-248.
- Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A. 2017. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14: 778-782.
- La Rosa, D., Wiesmann, D. 2013. Land cover and impervious surface extraction using parametric and non-parametric algorithms from the open-source software R: An application to sustainable urban planning in Sicily. *GIScience & Remote Sensing*, 50: 231-250.
- Lauer, D.T., Morain, S.A., Salomonson, V.V. 1997. The Landsat program: Its origins, evolution, and impacts. *Photogrammetric Engineering and Remote Sensing*, 63: 831-838.
- Lemke, R.L., VandenBygaart A.J., Campbell, C.A., Lafond, C.A., McConkey, B.G.,

Grant, B. 2012. Long-Term Effects of Crop Rotations and Fertilization on Soil C and N in a Thin Black Chernozem in Southeastern Saskatchewan. *Canadian Journal of Soil Science*, 92: 449–461.

León, R.J.C. 1991. Geographic Limits of the Region, Geomorphology and Geology, Regional Subdivisions, Floristic Aspects, Description of the Vegetation. Natural grasslands: introduction and western hemisphere. Elsevier, Amsterdam.

Li, H., Zhang, C., Zhang, S., Atkinson, P.M. 2019. Full year crop monitoring and separability assessment with fully-polarimetric L-band UAVSAR: A case study in the Sacramento Valley, California. *International Journal of Applied Earth Observation and Geoinformation*, 74, 45-56.

Li, J., Wang, S. 2018. Using SAR-derived vegetation descriptors in a water cloud model to improve soil moisture retrieval. *Remote Sensing*, 10: 1370.

Lloyd, J., Taylor, J. 1994. On the temperature dependence of soil respiration. *Functional Ecology*, 8: 315-323.

Lobell, D.B., Ortiz-Monasterio, I., Asner, G.P., Naylor, R.L., Falcon, W.P. 2005. Combining field surveys, remote sensing, and regression trees to understand yield variations in an irrigated wheat landscape. *Agronomy Journal*, 97: 241-249.

Lobell, D.B., Burke, M.B. 2010. On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology*, 150: 1443-1452.

Lobell, D.B. 2013. The use of satellite data for crop yield gap analysis. *Field Crops Research*, 143: 56-64.

- Lu, D., Weng, Q. 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28: 823-870.
- Lund, M.G., Carter, P.R., Oplinger, E.S., 1993. Tillage and Crop Rotation Affect Corn, Soybean, and Winter Wheat Yields. *Journal of Production Agriculture*, 6: 207-213.
- Luoto, M., Kuussaari, M., Toivonen, T. 2002. Modelling butterfly distribution based on remote sensing data. *Journal of Biogeography*, 29:1027-1037.
- Maddoni, G.A., Urricariet, S., Ghersa, C.M., Lavado, R.S. 1999. Assessing soil quality in the Rolling Pampa, using soil properties and maize characteristics. *Agronomy Journal*, 91: 280-287.
- Martini, G., Angeli, A. 2017. Por qué aumentar el maíz en las rotaciones. Pp. 55-61 en Borrás, L., Uhart, S. (eds.) *El mismo maíz, un nuevo desafío*. Dow Agrosiences, San Isidro, Argentina.
- Mc Nairn, H., Powers, J., Wiseman, G. 2014. *SMAPVEX12. In Situ Vegetation Data for Agricultural Area, Version 1*. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center. <<https://doi.org/10.5067/X2EF9ZKL0DGC>> (Acceso: 12/12/2021).
- McNairn, H., Shang, J., Jiao, X., Champagne, C. 2009. The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification. *IEEE Transactions on Geoscience and Remote Sensing*, 47: 3981-3992.
- Meyer-Aurich, A., Janovicek, K. Deen, W., Weersink, A. 2006. Impact of Tillage and Rotation on Yield and Economic Performance in Corn-Based Cropping Systems.

Agronomy Journal, 98: 1204-1212.

MINAGRI. 2017. Estimaciones Agrícolas. Subsecretaría de Agricultura, Dirección Nacional de Estimaciones, Delegaciones y Estudios Económicos. Ministerio de Agroindustria, República Argentina.

<<https://www.agroindustria.gob.ar/datosagroindustriales>> (Acceso: 1/12/2017).

MINAGRI. 2021. Estimaciones Agrícolas. Subsecretaría de Agricultura, Dirección Nacional de Estimaciones, Delegaciones y Estudios Económicos. Ministerio de Agroindustria, República Argentina.

<<https://www.agroindustria.gob.ar/datosagroindustriales>> (Acceso: 12/1/2021).

MINAGRI. 2022a. Embarques. Mercados Agropecuarios. Ministerio de Agroindustria, República Argentina.

<https://www.magyp.gob.ar/sitio/areas/ss_mercados_agropecuarios/exportaciones/> (Acceso: 10/06/2022).

MINAGRI. 2022b. Mapa de Cultivo Campaña Fina 2019. Dirección de Estimaciones Agrícolas, Dirección Nacional de Agricultura, Subsecretaría de Agricultura. Ministerio de Agroindustria, República Argentina.

<https://www.magyp.gob.ar/sitio/areas/estimaciones/acerca_de/mapa_cultivo_fina/index.php> (Acceso: 1/07/2022).

Mikkelsen, C. A. 2008. La expansión de la soja y su relación con la agricultura industrial. *Revista Universitaria de Geografía*, 17: 165-188.

Moran, M.S., Alonso, L., Moreno, J.F., Mateo, M.P.C., De La Cruz, D.F., Montoro, A. 2011. A RADARSAT-2 quad-polarized time series for monitoring crop and soil

conditions in Barrax, Spain. *IEEE Transactions on Geoscience and Remote Sensing*, 50: 1057-1070.

Myneni, R. B., Hoffman, S., Knyazikhin, Y., Privette, J. L., Glassy, J., Tian, Y., Wang, Y., Song, X., Zhang, Y., Smith, G.R., Lotsch, A., Friedl, M., Morisette, J.T., Votava, P., Nemani, R.R., Running, S. W. 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote Sensing of Environment*, 83: 214-231.

Myneni, R. B., Williams, D. L. 1994. On the relationship between FAPAR and NDVI. *Remote Sensing of Environment*, 49: 200-211.

Nouwakpo, S.K., Song, J., Gonzalez, J.M. 2018. Soil Structural Stability Assessment with the Fluidized Bed, Aggregate Stability, and Rainfall Simulation on Long-Term Tillage and Crop Rotation Systems. *Soil and Tillage Research*, 178: 65–71.

Novelli, L.E., Caviglia, O.P., Melchiori, R.J.M. 2011. Impact of soybean cropping frequency on soil carbon storage in Mollisols and Vertisols. *Geoderma*, 167:254-260.

Novelli, L. E., Caviglia, O. P., Piñeiro, G. 2017. Increased cropping intensity improves crop residue inputs to the soil and aggregate-associated soil organic carbon stocks. *Soil and Tillage Research*, 165: 128-136.

Novelli, L.E., Hass, W.L., Benintende, S.M., Caviglia, O.P. 2020. Microbial activity effect on aggregate stability after residue addition in a Mollisol and a Vertisol in the Pampas, Argentina. *Geoderma Regional*, 23: e00346.

- Novelli, L.E., Caviglia, O.P., Jobbágy, E.G., Sadras, V.O. 2023. Diversified crop sequences to reduce soil nitrogen mining in agroecosystems. *Agriculture, Ecosystems & Environment*, 341: 108208.
- Ogle, S.M., Breidt, F.J., Paustian, K. 2005. Agricultural management impacts on soil organic carbon storage under moist and dry climatic conditions of temperate and tropical regions. *Biogeochemistry*, 72: 87-121.
- ONSA 2023. Observatorio Nacional de Suelos Agropecuarios. Secretaría de Agricultura, Ganadería y Pesca. Argentina.
<https://www.magyp.gob.ar/sitio/areas/plan_suelos/onsa/> (Acceso: 1/3/2023).
- Oyarzabal, M., Clavijo, J., Oakley, L., Biganzoli, F., Tognetti, P., Barberis, I., Maturo H.M., Aragón R, Campanello P.I., Prado D., Oesterheld M., León, R. J. 2018. Unidades de vegetación de la Argentina. *Ecología Austral*, 28: 40-63.
- Paruelo, J.M, Guerschman, J.P., Verón, S., 2005. Expansión Agrícola y Cambios En El Uso Del Suelo. *Ciencia Hoy*, 15: 14-23.
- Paustian, K., Six, J., Elliott, E.T., Hunt, H.W. 2000. Management options for reducing CO₂ emissions from agricultural soils. *Biogeochemistry*, 48: 147-163.
- Pellegrini, P., Fernández, R.J. 2018. Crop intensification, land use, and on-farm energy-use efficiency during the worldwide spread of the green revolution. *Proceedings of the National Academy of Sciences*, 115: 2335-2340.
- Pengue, W.A. 2005. Transgenic Crops in Argentina: The Ecological and Social Debt. *Bulletin of Science, Technology & Society*, 25:314.322.

- Piquer-Rodríguez, M., Butsic, V., Gärtner, P., Macchi, L., Baumann, M., Pizarro, G. G., Volante, J.N., Gasparri, I.N., Kuemmerle, T. 2018. Drivers of agricultural land-use change in the Argentine Pampas and Chaco regions. *Applied Geography*, 91: 111-122.
- Plourde, J.D, Pijanowski, B.C., Pekin, B.K. 2013. Evidence for Increased Monoculture Cropping in the Central United States. *Agriculture, Ecosystems & Environment*, 165: 50-59.
- Podestá, G., Weber, E.U., Laciana, C., Bert, F., Letson, D., 2008. Agricultural Decision Making in the Argentine Pampas: Modeling the Interaction between Uncertain and Complex Environments and Heterogeneous and Complex Decision Makers. Pp 57-76 en Kugler T., Smith, J.C, Connolly, T., YJ, Y.J. (eds.) *Decision Modeling and Behavior in Uncertain and Complex Environments*. Springer, New York, EE.UU.
- Rada, N., Helfand, S., Magalhães, M. 2019. Agricultural productivity growth in Brazil: Large and small farms excel. *Food Policy*, 84: 176-185.
- Ramankutty, N., Foley, J.A. 1999. Estimating historical changes in global land cover: Croplands from 1700 to 1992. *Global Biogeochemical Cycles*, 13: 997-1027.
- Reeves, D.W. 1997. The role of soil organic matter in maintaining soil quality in continuous cropping systems. *Soil and Tillage Research*, 43: 131-167.
- Reeves, M.C., Zhao, M., Running, S.W. 2005. Usefulness and limits of MODIS GPP for estimating wheat yield. *International Journal of Remote Sensing*, 26: 1403-1421.
- Reisi-Gahrouei, O., Homayouni, S., McNairn, H., Hosseini, M., Safari, A. 2019. Crop biomass estimation using multi regression analysis and neural networks from

multitemporal L-band polarimetric synthetic aperture radar data. *International Journal of Remote Sensing*, 40: 6822-6840.

SAGyP. 2023. Estimaciones Agrícolas. Metodología. Secretaría de Agricultura, Ganadería y Pesca. Ministerio de Economía, República Argentina.

<https://www.magyp.gob.ar/sitio/areas/estimaciones/acerca_de/metodologia/index.php
> (Acceso: 1/3/2023).

Sasal, M.C., Boizard, H., Andriulo, A.E., Wilson, M.G., Léonard, J. 2017. Platy structure development under no-tillage in the northern humid Pampas of Argentina and its impact on runoff. *Soil and Tillage Research*, 173: 33-41.

Satorre, E.H. 2011. Recent changes in pampean agriculture: possible new avenues in coping with global change challenges. Pp. 47-57 en Araus, J.L., Slafer, G.A. (eds.) Crop stress management and global climate change. CAB International, Oxfordshire, Reino Unido.

Sindelar, A.J, Schmer, M.R., Jin, V.L., Wienhold, B.J., Varvel, G.E. 2015. Long-Term Corn and Soybean Response to Crop Rotation and Tillage. *Agronomy Journal*, 107: 2241-2252.

Sinha, S., Jeganathan, C., Sharma, L. K., Nathawat, M. S. 2015. A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology*, 12: 1779-1792.

Singh Parihar, J., Justice, C., Soares, J., Leo, O., Kosuth, P., Jarvis, I., Williams, D., Wu, B., Latham, J., Becker-Reshef, I. 2012. Pp. 1451 en GEO-GLAM: A GEOSS-G20 initiative on global agricultural monitoring. 39th COSPAR Scientific Assembly,

Mysore, India.

Soule, M.J., Tegene, A., Wiebe, K.D. 2000. Land tenure and the adoption of conservation practices. *American Journal of Agricultural Economics*, 82, 993-1005.

Stein, S., Steinmann, H.H. 2018. Identifying Crop Rotation Practice by the Typification of Crop Sequence Patterns for Arable Farming Systems—A Case Study from Central Europe. *European Journal of Agronomy*, 92: 30-40.

Steinmann, H.H., Dobers, E.S. 2013. Spatio-temporal analysis of crop rotations and crop sequence patterns in Northern Germany: potential implications on plant health and crop protection. *Journal of Plant Diseases and Protection*, 120: 85-94.

Stoyan, D., Stoyan, H. 1994. Fractals, Random Shapes, and Point Fields: Methods of Geometrical Statistics. Willey, Chichester, Reino Unido.

Tilman, D. 1999. Global environmental impacts of agricultural expansion: The need for sustainable and efficient practices. *Proceedings of the National Academy of Sciences*, 96: 5995-6000.

Tucker, J., Holben, B.N., Elgin, J.H., McMurtrey, J.E. 1981. Remote Sensing of Total Dry-Matter Accumulation in Winter Wheat. *Remote Sensing of Environment*, 11: 171-189.

Ulaby, F. T., Dubois, P. C., Van Zyl, J. 1996. Radar mapping of surface soil moisture. *Journal of hydrology*, 184: 57-84.

Ulber, L., Steinmann, H.H., Klimek, S., Isselstein, J. 2009. An On-Farm Approach to Investigate the Impact of Diversified Crop Rotations on Weed Species Richness and

Composition in Winter Wheat. *Weed Research*, 49: 534-543.

USGS. 2023. Earth Explorer. Servicio Geológico de los Estados Unidos de América. <<https://earthexplorer.usgs.gov/>> (Acceso: 1/3/2023).

Vega, C.R.C., Sadras, V.O., Andrade, F.H., Uhart, S.A. 2000. Reproductive allometry in soybean, maize and sunflower. *Annals of Botany*, 85: 461-468.

Videla-Mensegue, H., Caviglia, O.P., Sadras, V. O. 2022. Functional crop types are more important than diversity for the productivity, profit and risk of crop sequences in the inner Argentinean Pampas. *Agricultural Systems*, 196: 103333.

Viglizzo, E.F., Frank, F.C., Carreño, L.V., Jobbágy, E.G., Pereyra, H., Clatt, J., Pincén, D., Ricard, M.F., 2011. Ecological and environmental footprint of 50 years of agricultural expansion in Argentina. *Global Change Biology* 17: 959-973.

Viglizzo, E. F., Pordomingo, A. J., Castro, M. G., Lértora, F. A., Bernardos, J. N. 2004. Scale-dependent controls on ecological functions in agroecosystems of Argentina. *Agriculture, Ecosystems & Environment*, 101: 39-51.

Viña, A., Gitelson, A.A., Nguy-Robertson, A.L., Peng, Y. 2011. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115: 3468-3478.

Walkley, A., Black, I.A. 1934. An examination of the Degtjareff method for determining soil organic matter, a proposed modification of the chromic acid titration method. *Soil Science*, 37: 29-38.

- Waldner, F., Lambert, M.J., Li, W., Weiss, M., Demarez, V., Morin, D., Defourny, P. 2015. Land cover and crop type classification along the season based on biophysical variables retrieved from multi-sensor high-resolution time series. *Remote Sensing*, 7: 10400-10424.
- Waldner, F., de Aballeyra, D., Verón, S.R., Zhang, M., Wu, B., Plotnikov, D., Bartalev, S., Lavreniuk, M., Skakun, S., Kussul, N., Le Maire, G., Dupuy, S., Jarvis, I., Defourny, P. 2016. Towards a set of agrosystem-specific cropland mapping methods to address the global cropland diversity. *International Journal of Remote Sensing*, 37: 3196-3231.
- Waldner, F., Chen, Y., Lawes, R., Hochman, Z. 2019. Needle in a haystack: Mapping rare and infrequent crops using satellite imagery and data balancing methods. *Remote Sensing of Environment*, 233: 111375.
- Wiseman, G., McNairn, H., Homayouni, S., Shang, J. 2014. RADARSAT-2 Polarimetric SAR response to crop biomass for agricultural production monitoring. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7: 4461-4471.
- Wright, A.L., Hons, F.M. 2004. Soil aggregation and carbon and nitrogen storage under soybean cropping sequences. *Soil Science Society of America Journal*, 68: 507-513.
- Wu, B., Meng, J., Li, Q., Yan, N., Du, X., Zhang, M. 2014. Remote sensing-based global crop monitoring: experiences with China's CropWatch system. *International Journal of Digital Earth*, 7: 113-137.

Wulder, M.A., Masek, J.G., Cohen, W.B., Loveland, T.R., Woodcock, C.E. 2012.

Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, 122: 2-10.

Zhao, J., Yang, Y., Zhang, K., Jeong, J., Zeng, Z., Zang, H. 2020. Does crop rotation yield more in China? A meta-analysis. *Field Crops Research*, 245: 107659.

Zeljkovich, L.E. 2015. Requerimientos agroclimáticos del cultivo de maíz. Pp. 7-24 en Eyherabide, G. (ed.) Bases para el manejo del cultivo de maíz. Ediciones INTA, Buenos Aires, Argentina.

Zuber, S.M., Behnke, G.V., Nafziger, E.D. Villamil, M.B. 2015. Crop Rotation and Tillage Effects on Soil Physical and Chemical Properties in Illinois. *Agronomy Journal*, 107: 971-978.

APÉNDICE

8.1 Cuadros y Figuras Apéndices. Capítulo III.

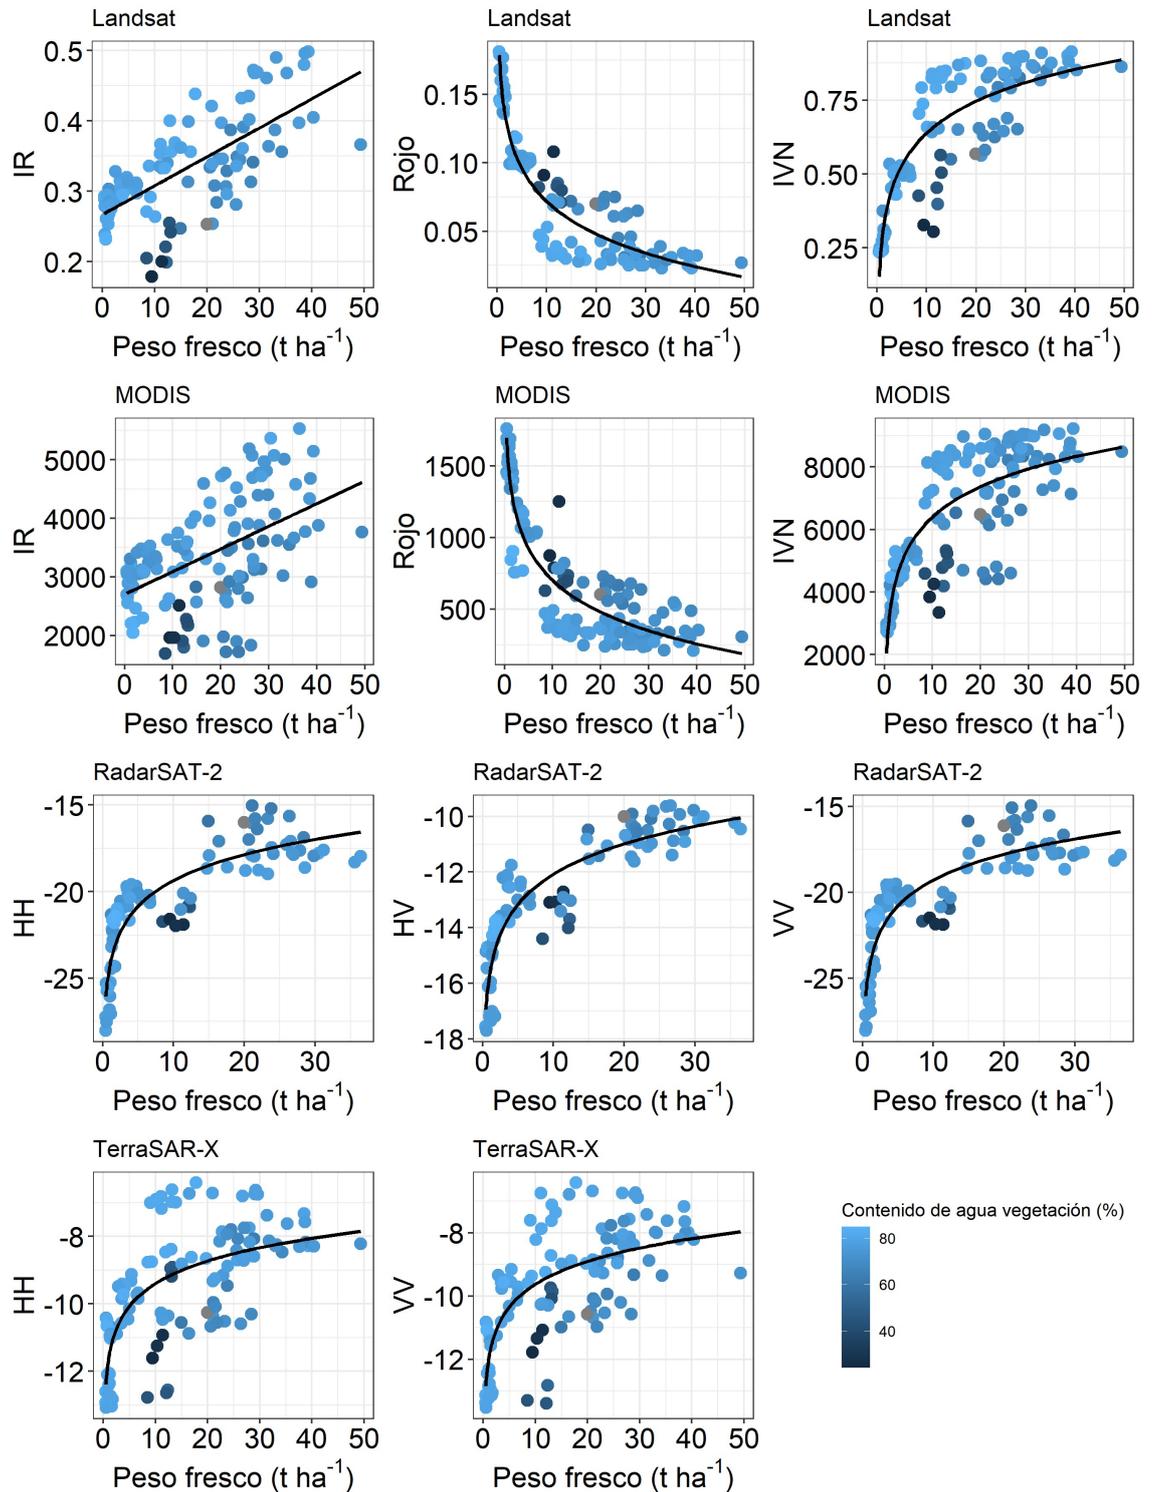


Figura A.3.1. Relación entre bandas e índices de las diversas plataformas analizadas y el peso fresco medido a lo largo de toda la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

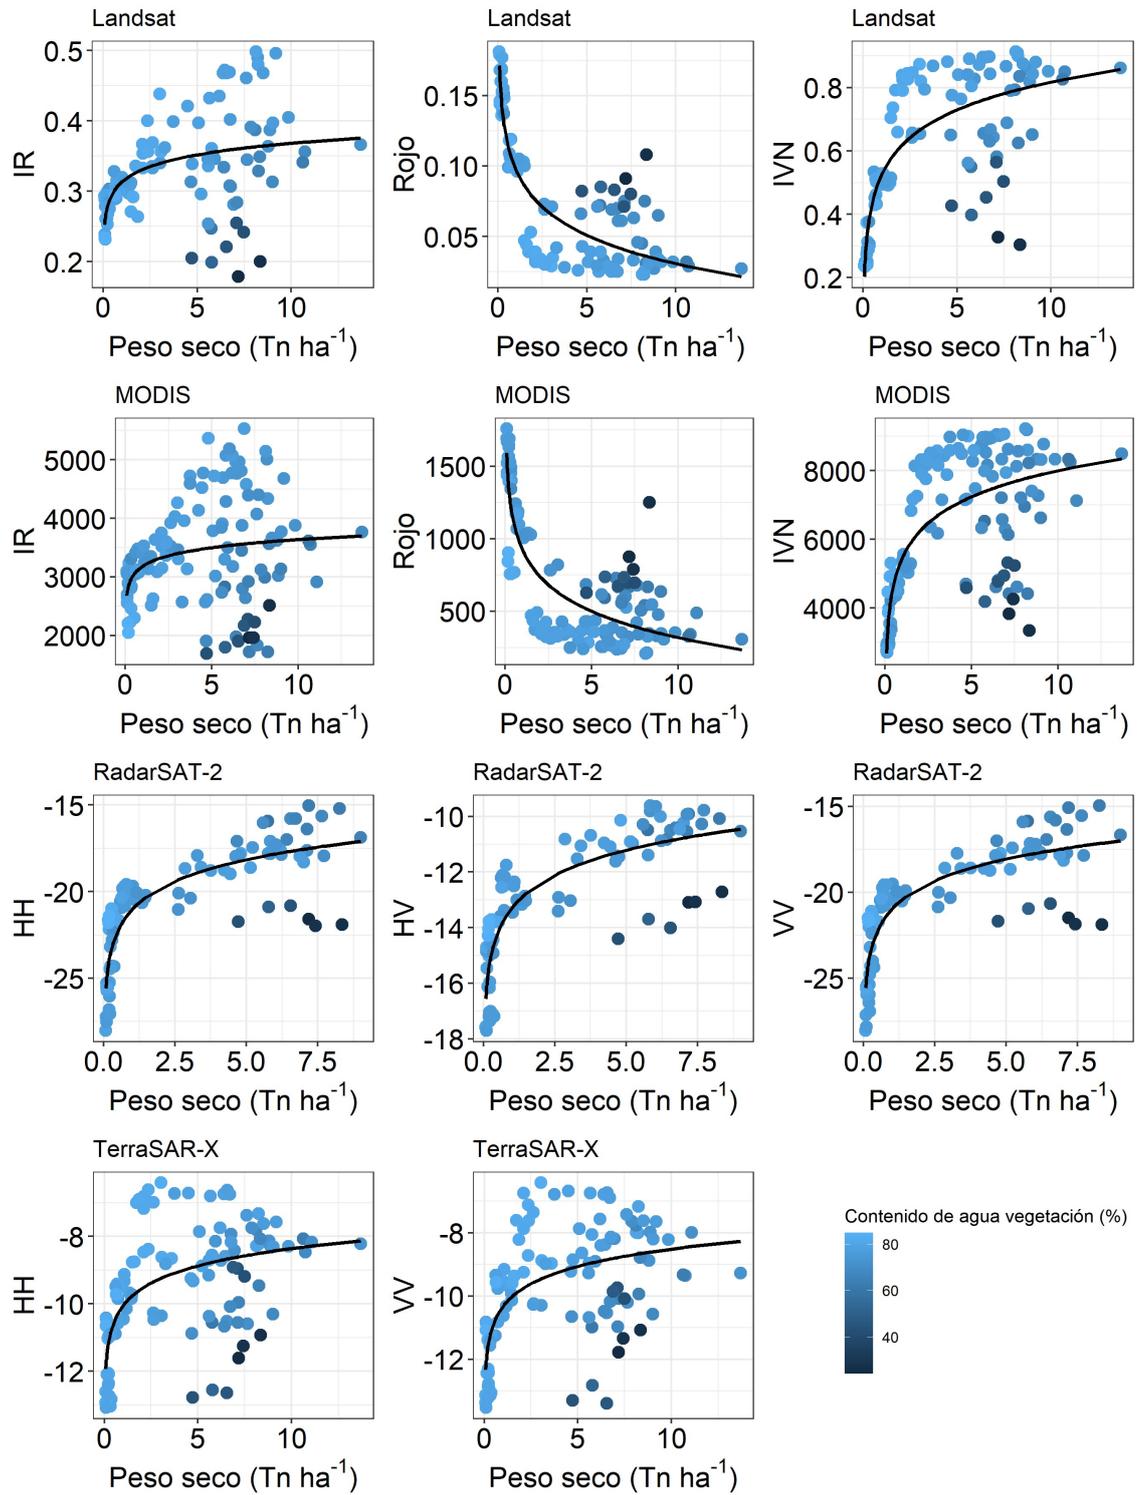


Figura A.3.2. Relación entre bandas e índices de las diversas plataformas analizadas y el peso seco medido a lo largo de toda la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

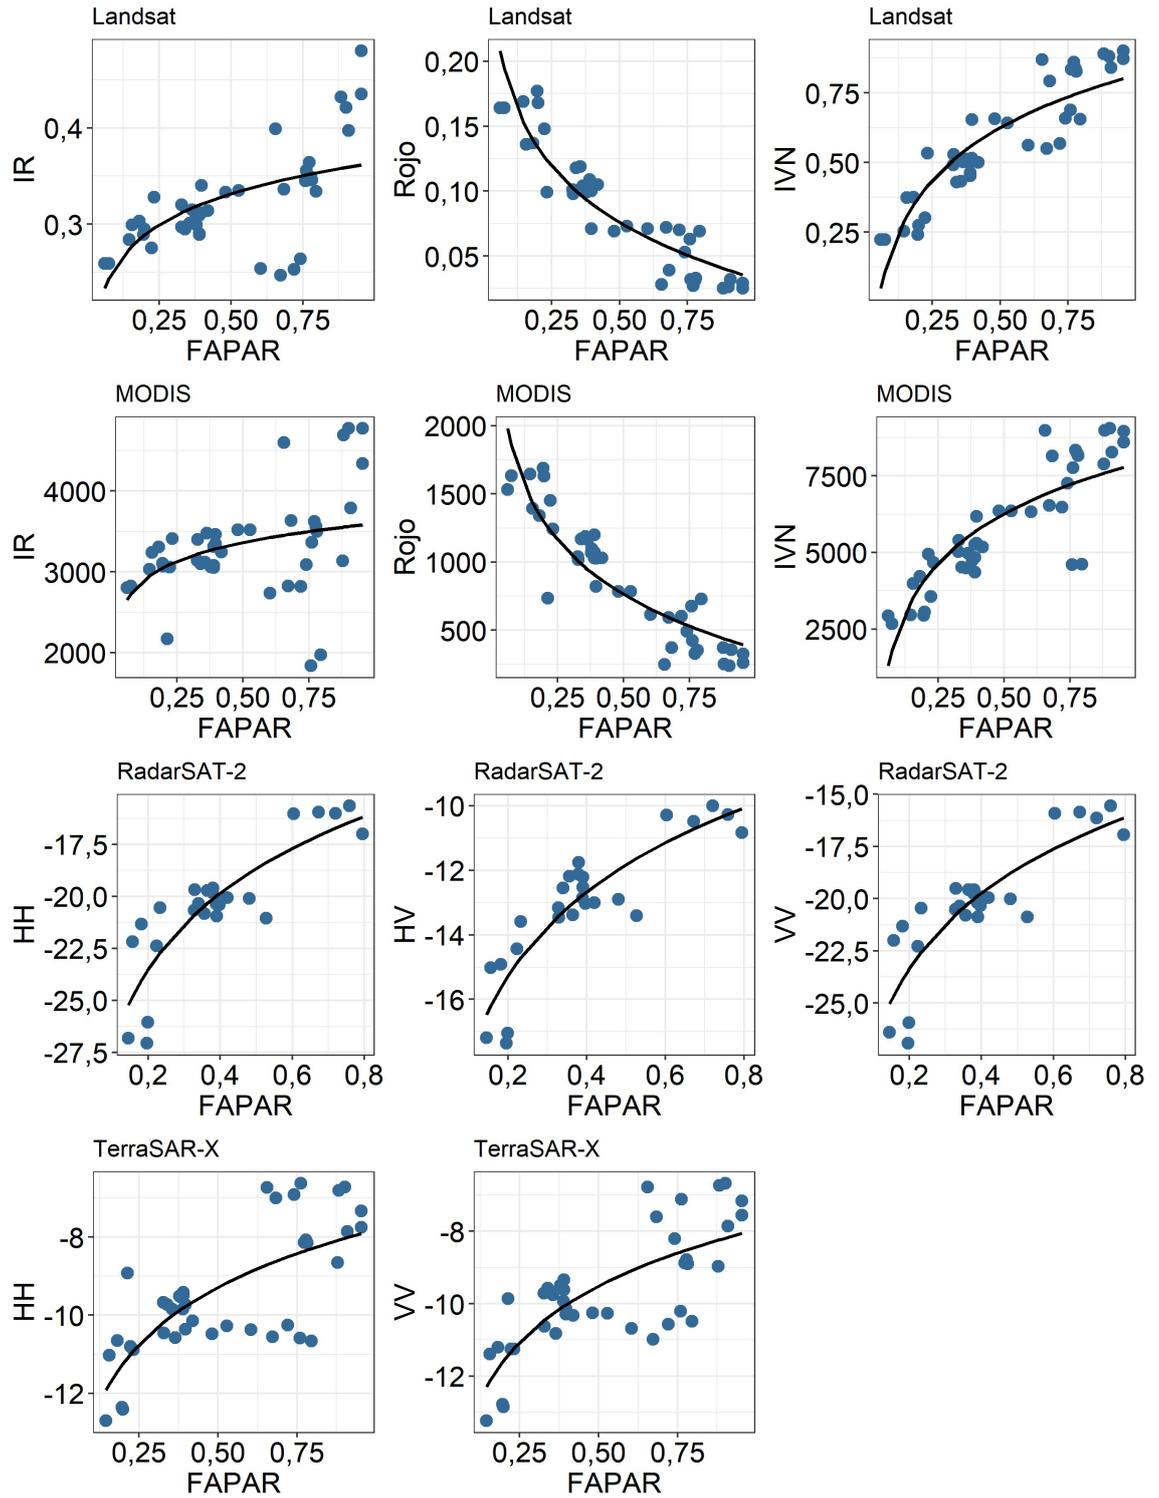


Figura A.3.3. Relación entre bandas e índices de las diversas plataformas analizadas y FAPAR medido a lo largo de toda la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

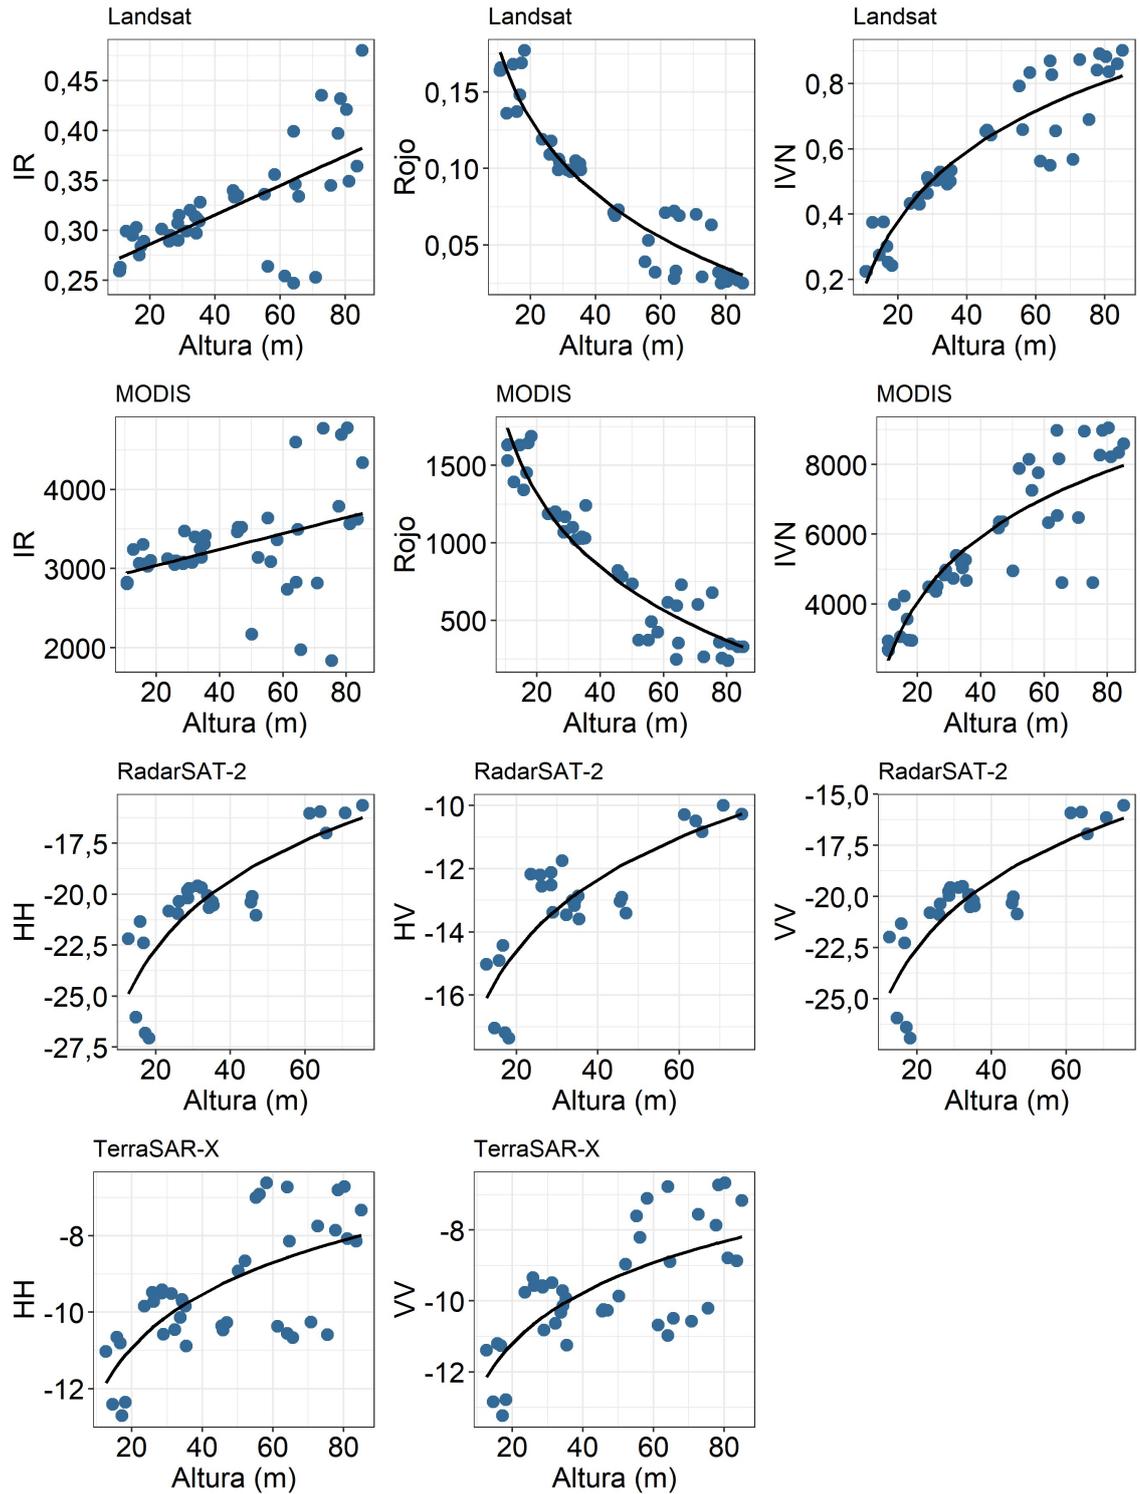


Figura A.3.4. Relación entre bandas e índices de las diversas plataformas analizadas y altura medida a lo largo de toda la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

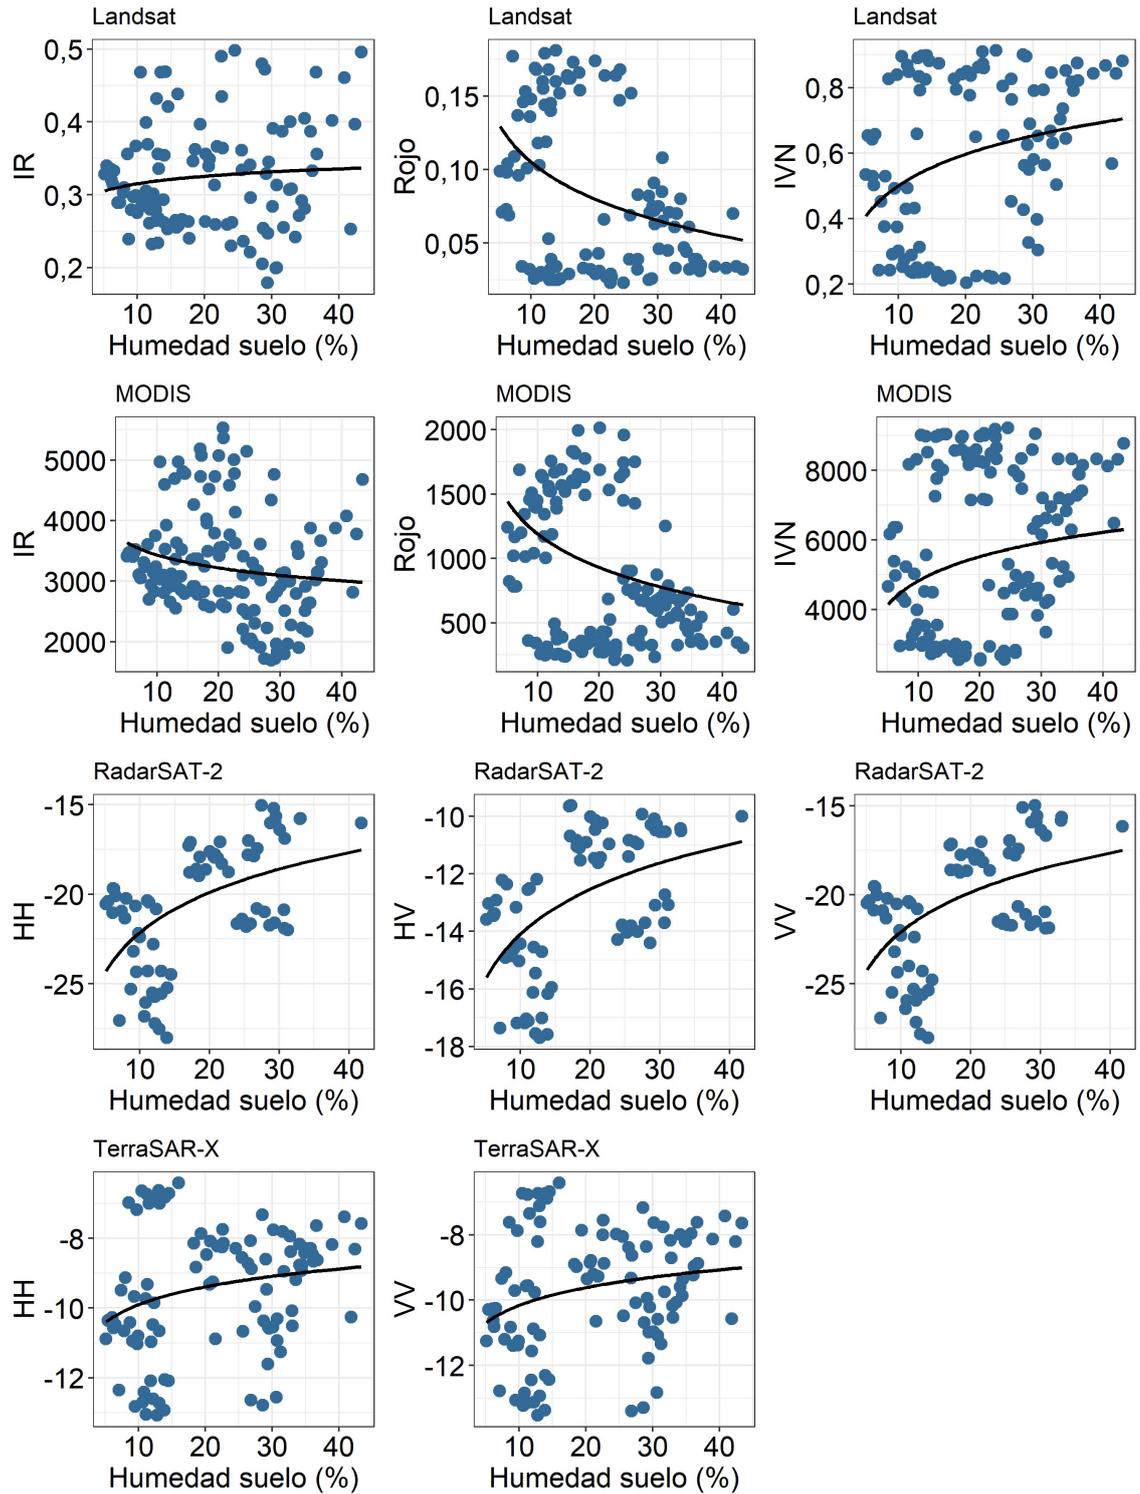


Figura A.3.5. Relación entre bandas e índices de las diversas plataformas analizadas y humedad superficial del suelo (0-5 cm) medida a lo largo de toda la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

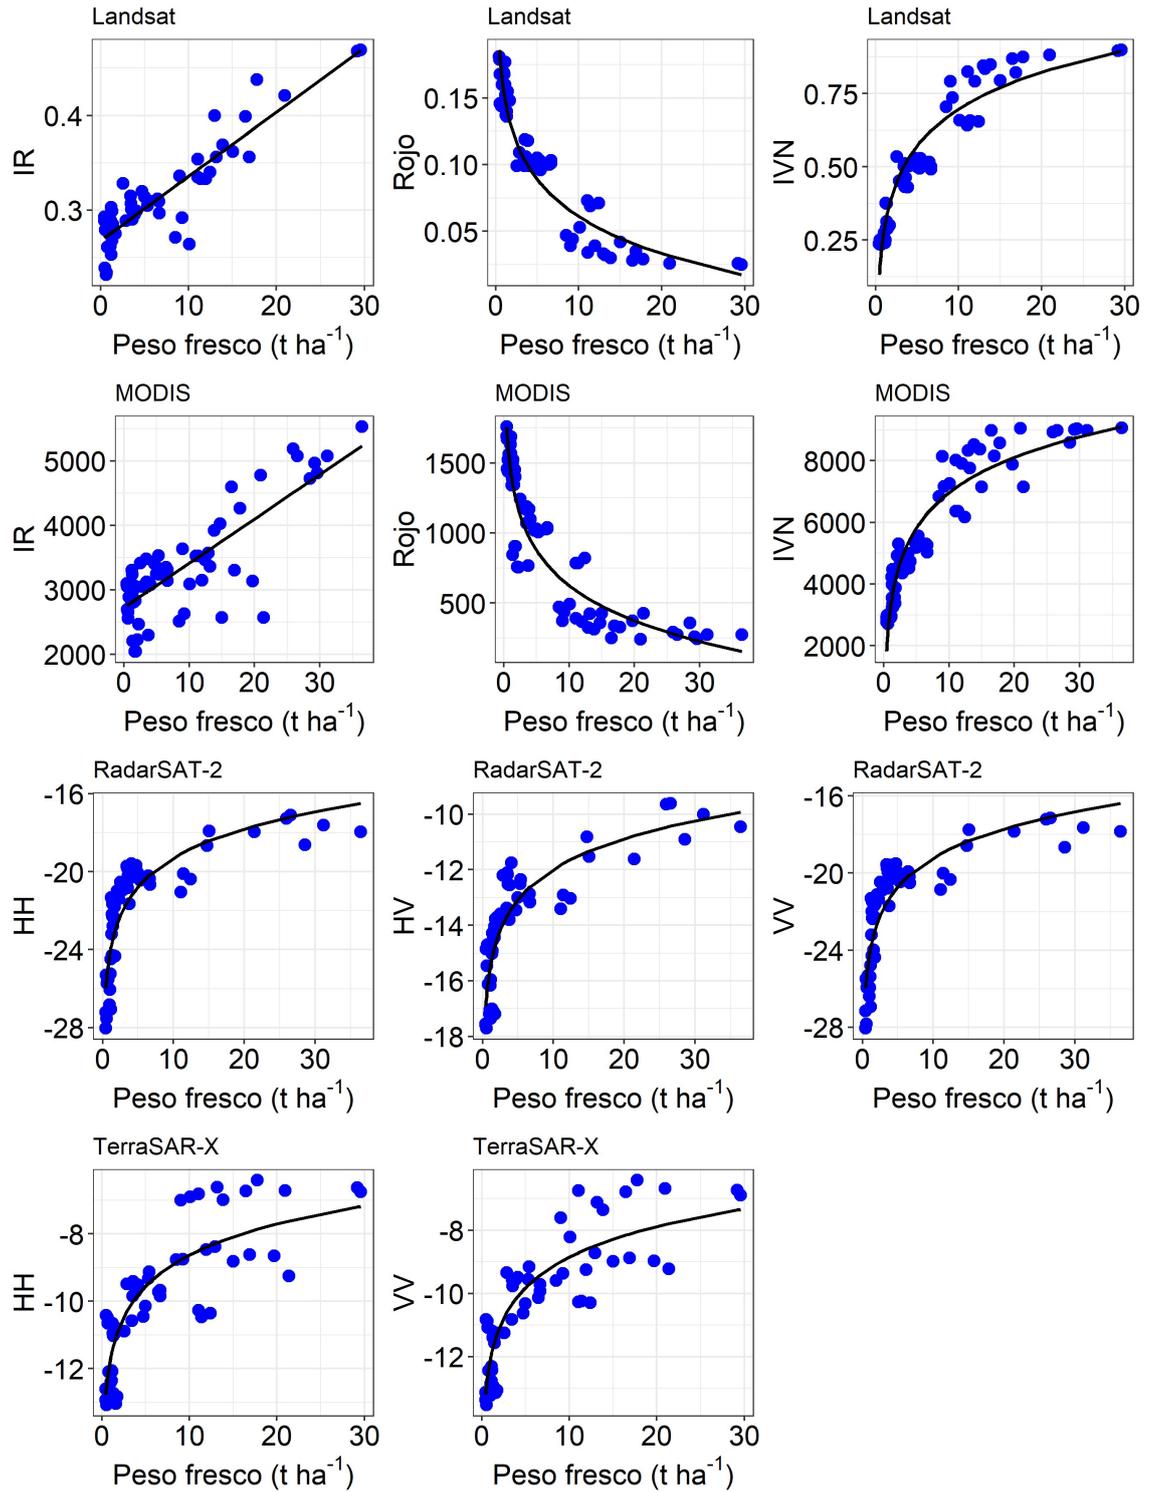


Figura A.3.6. Relación entre bandas e índices de las diversas plataformas analizadas y el peso fresco medido previo al pico de IVN durante la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

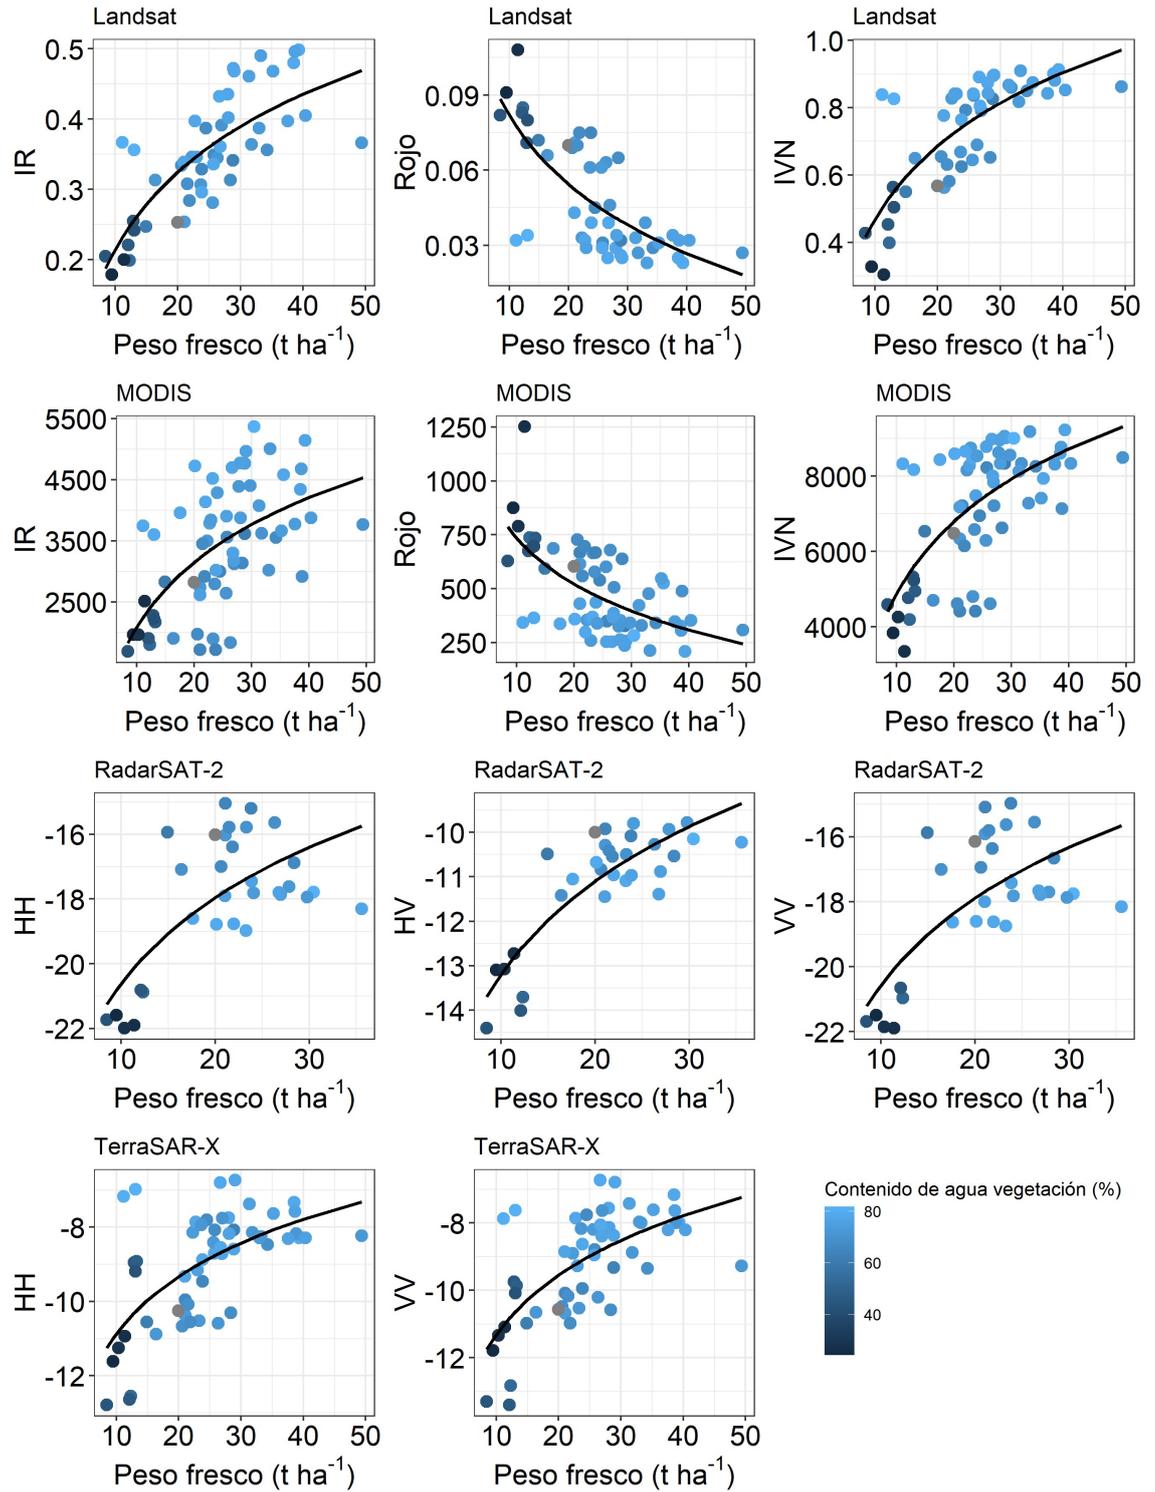


Figura A.3.7. Relación entre bandas e índices de las diversas plataformas analizadas y el peso fresco medido luego del pico de IVN durante la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

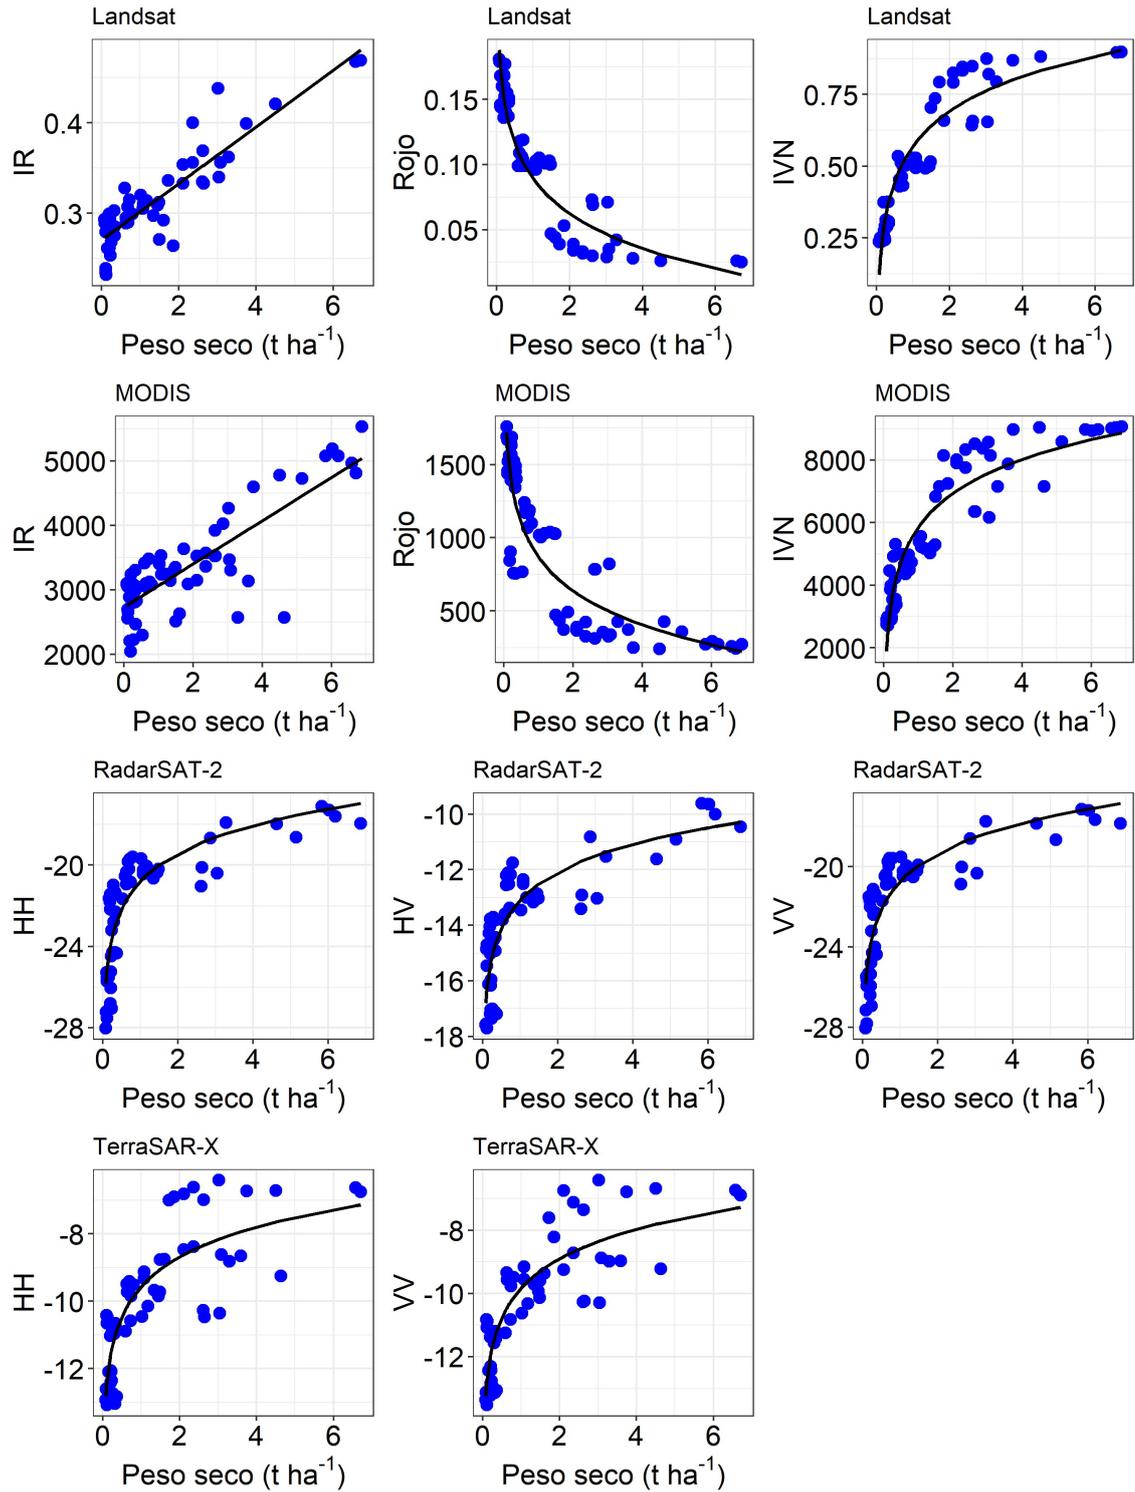


Figura A.3.8. Relación entre bandas e índices de las diversas plataformas analizadas y el peso seco medido previo al pico de IVN durante la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

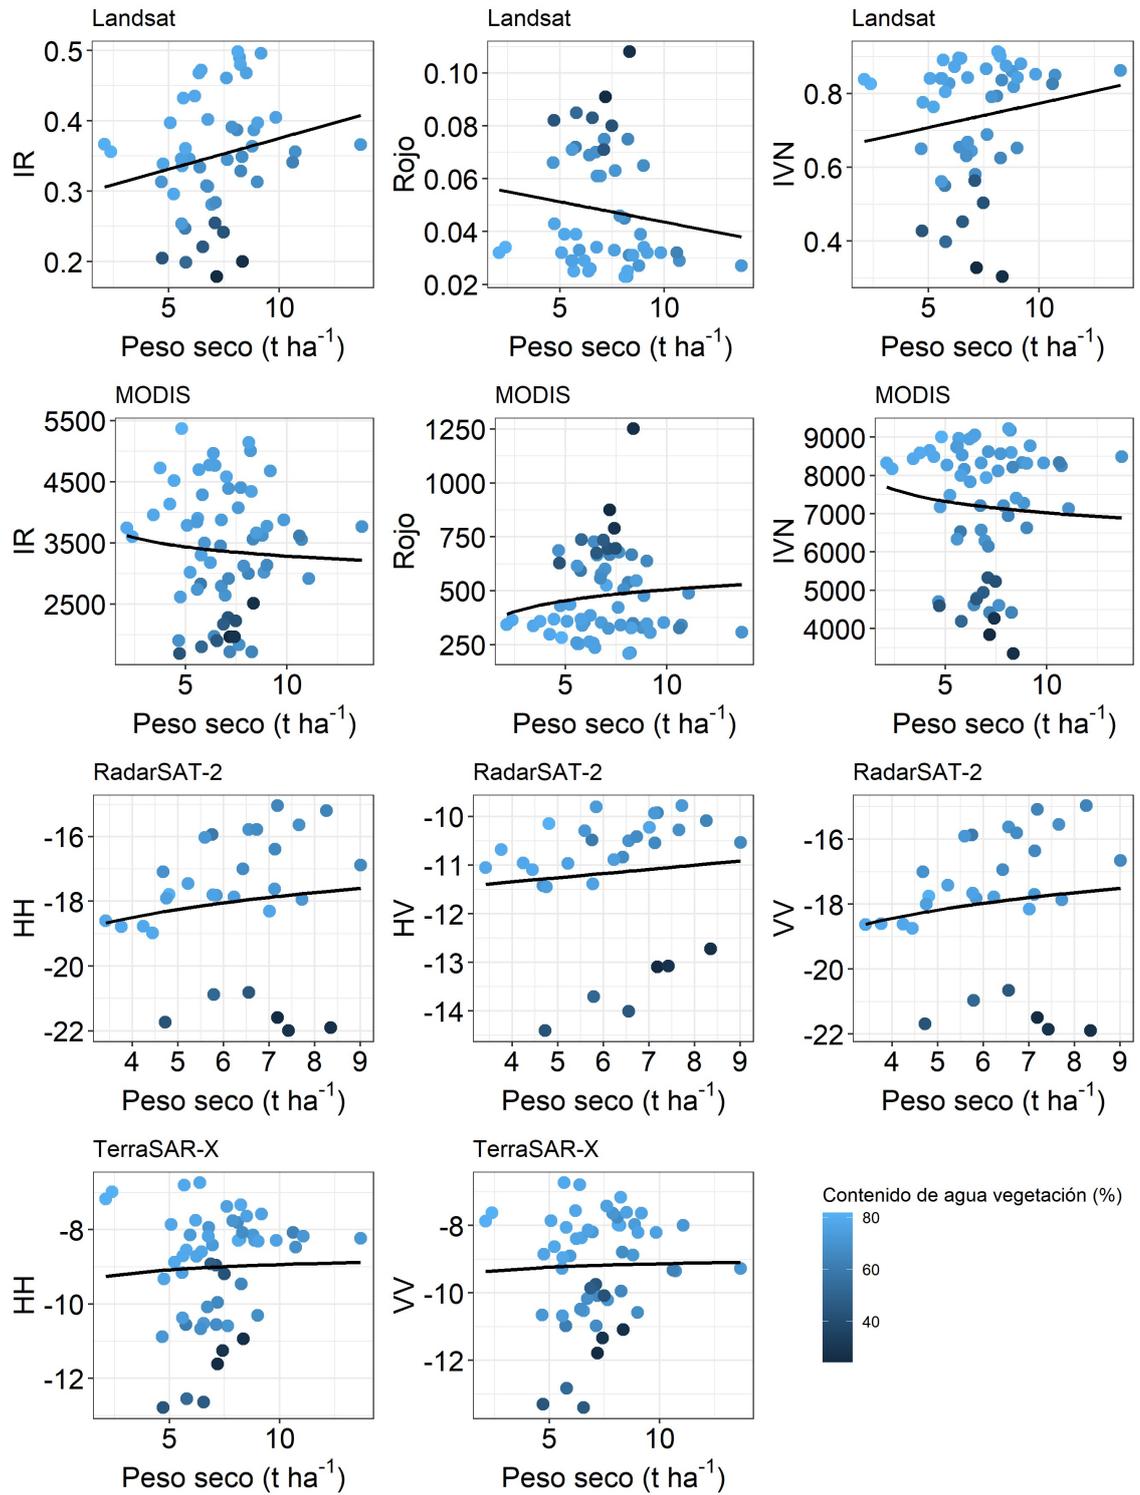


Figura A.3.9. Relación entre bandas e índices de las diversas plataformas analizadas y el peso seco medido luego del pico de IVN durante la campaña 2011/2012. La línea muestra el mejor modelo ajustado (lineal o logarítmico).

8.2. Cuadros y Figuras Apéndices. Capítulo IV.

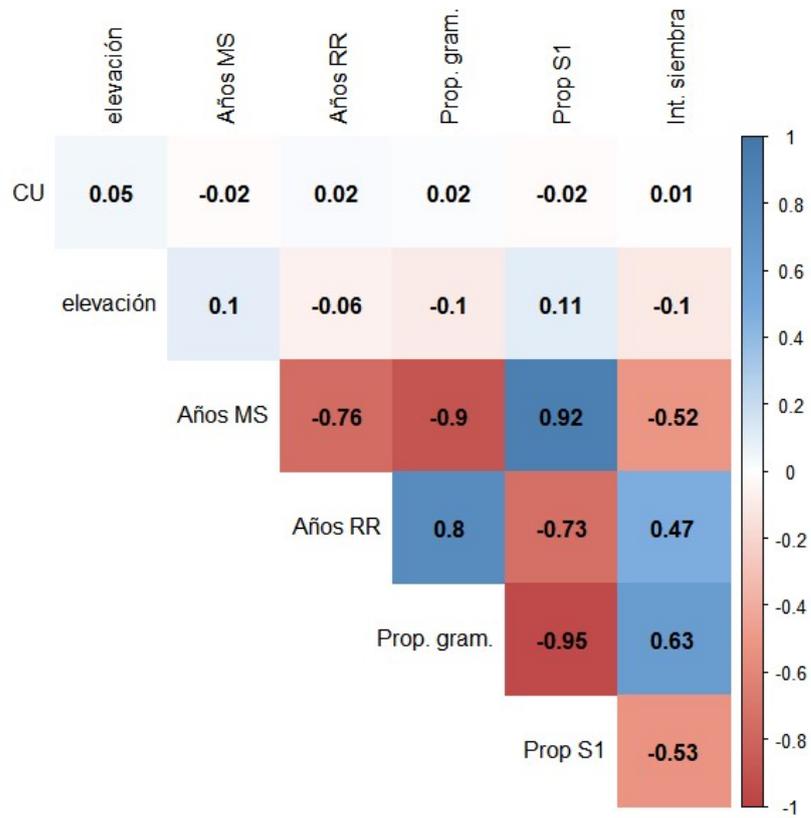


Figura A.4.1. Tabla de correlación entre las variables consideradas para el análisis del impacto en biomasa seca de cultivos de soja: Capacidad de uso del suelo (CU), Elevación, Años con monocultivo de soja (Años MS), Años con rotación recomendada (Años RR), Proporción de gramíneas (Prop. gram.), Proporción de soja de primera (Prop. S1), e Intensidad de siembra (Int. siembra).

Cuadro A.4.1. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas, incluyendo como variable la proporción de soja de primera. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	29/11/201 8	23/12/201 8	16/01/201 9	09/02/201 9	05/03/201 9	29/03/201 9
proporción de soja de primera	-0,11**	-0,22***	0,09*	-0,17***	-0,13***	-0,09*
intensidad de siembra	-0,07	-0,06	-0,07*	-0,08*	-0,1**	-0,03
capacidad de uso	0,03	-0,02	0	0	-0,06	-0,02
elevación	-0,03	-0,02	0,03	0,18***	0,1***	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.2. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas, incluyendo como variable la cantidad de períodos con monocultivo de soja. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	29/11/201 8	23/12/201 8	16/01/201 9	09/02/201 9	05/03/201 9	29/03/201 9
períodos monocultivo de soja	-0,13***	-0,22***	0,06	-0,18***	-0,13***	-0,09*
intensidad de siembra	-0,07*	-0,05	-0,09**	-0,08*	-0,09**	-0,02
capacidad de uso	0,03	-0,02	0	0	-0,06	-0,02
elevación	-0,03	-0,03	0,03	0,17***	0,1***	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.3. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas, incluyendo como variable el número de períodos con rotación recomendada (maíz / soja / trigo-soja). Los parámetros se presentan estandarizados (coeficiente Beta).

variable	29/11/2018	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
períodos rotación recomendada	0,05	0,24***	-0,04	0,09**	0,11**	0,17***
intensidad de siembra	-0,03	-0,06	-0,1**	-0,03	-0,08*	-0,06
capacidad de uso	0,03	-0,02	0	0	-0,05	-0,02
elevación	-0,03	-0,03	0,03	0,17***	0,1**	0

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.4. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de primera a lo largo de las diferentes fechas analizadas, incluyendo como variable la proporción de gramíneas. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	29/11/2018	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
proporción gramíneas	0,11**	0,23***	-0,08	0,17***	0,16***	0,14***
intensidad de siembra	-0,08	-0,1*	-0,07	-0,1*	-0,13**	-0,07
capacidad de uso	0,03	-0,02	0	0	-0,05	-0,02
elevación	-0,03	-0,03	0,03	0,17***	0,1**	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.5. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas, incluyendo como variable proporción de soja de primera. Los parámetros se presentan estandarizados (coeficiente Beta).

	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
proporción soja de 1ra	0,02	-0,1*	-0,02	0,05	0
intensidad de siembra	0,07	-0,16***	-0,05	-0,02	0
capacidad de uso	0,01	0,07	0,04	0,04	0,05
elevación	0	-0,03	-0,01	0,08*	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.6. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas, incluyendo como variable el número de períodos con monocultivo de soja.

Los parámetros se presentan estandarizados (coeficiente Beta).

variable	23/12/201 8	16/01/201 9	09/02/201 9	05/03/201 9	29/03/201 9
períodos monocultivo de soja	0,01	-0,07	-0,01	0,02	-0,01
intensidad de siembra	0,06	-0,15	-0,04	-0,03	-0,01
capacidad de uso	0,01	0,07	0,04	0,04	0,05
elevación	0	-0,03	-0,01	0,08*	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.7. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas, incluyendo como variable el número de períodos con rotación recomendada.

Los parámetros se presentan estandarizados (coeficiente Beta).

variable	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
períodos rot. rec.	-0,07	0,03	0,05	0	0,02
intensidad de siembra	0,09*	-0,13***	-0,06	-0,04	-0,01
capacidad de uso	0,01	0,07	0,04	0,04	0,05
elevación	0,01	-0,04	-0,01	0,08*	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.8. Parámetros obtenidos del modelo de regresión múltiple para la estimación de biomasa seca de soja de segunda a lo largo de las diferentes fechas analizadas, incluyendo como variable la proporción de gramíneas. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	23/12/2018	16/01/2019	09/02/2019	05/03/2019	29/03/2019
proporción gramíneas	-0,03	0,11*	0,03	-0,05	0,01
intensidad de siembra	0,07	-0,18***	-0,05	-0,02	-0,01
capacidad de uso	0,01	0,07	0,04	0,04	0,05
elevación	0	-0,03	-0,01	0,08*	-0,01

*** significancia al 0,001; ** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

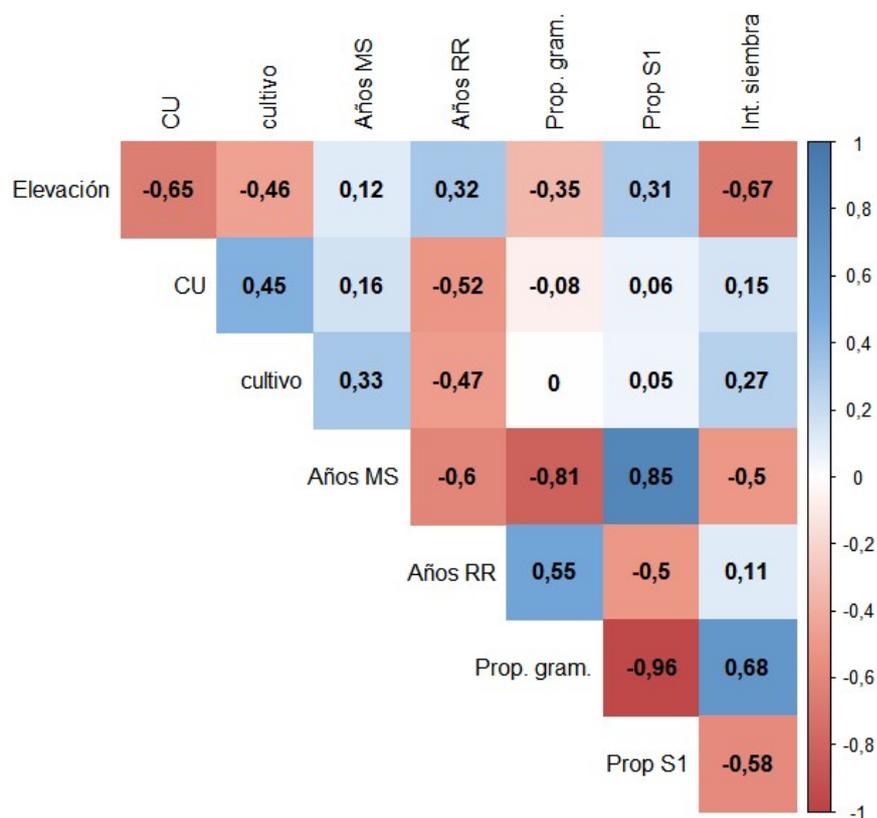


Figura A.4.2. Matriz de correlación entre las variables consideradas para el análisis del impacto en carbono orgánico del suelo: Elevación, Capacidad de uso del suelo (CU), Cultivo (soja de primera o de segunda), Años con monocultivo de soja (Años MS), Años con rotación recomendada (Años RR), Proporción de gramíneas (Prop. gram.), Proporción de soja de primera (Prop. S1), e Intensidad de siembra (Int. siembra).

Cuadro A.4.9. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico del suelo, incluyendo como variable la proporción de soja de primera. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	CO suelo
proporción soja de 1ra	-0,4•
intensidad de siembra	-1,19**
capacidad de uso	0,1
elevación	-0,83*
cultivo	-0,09

** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.10. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico del suelo, incluyendo como variable el número de períodos con monocultivo de soja. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	CO suelo
períodos monocultivo soja	-0,44•
intensidad de siembra	-1,29**
capacidad de uso	0,02
elevación	-0,97*
cultivo	0,03

** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.11. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico del suelo, incluyendo como variable el número de períodos con rotación recomendada. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	CO suelo
períodos rotación recomendada	-0,01
intensidad de siembra	-0,94*
capacidad de uso	0,06
elevación	-0,85*
cultivo	-0,18

** significancia al 0,01; * significancia al 0,05; • significancia al 0,1.

Cuadro A.4.12. Parámetros obtenidos del modelo de regresión múltiple para la estimación de carbono orgánico del suelo, incluyendo como variable la proporción de gramíneas. Los parámetros se presentan estandarizados (coeficiente Beta).

variable	CO suelo
proporción gramíneas	0,31
intensidad de siembra	-1,17**
capacidad de uso	0,1
elevación	-0,86*
cultivo	-0,13

** significancia al 0,01; * significancia al 0,05; • significancia al 0,1

8.3. Cuadros y Figuras Apéndices. Capítulo V.

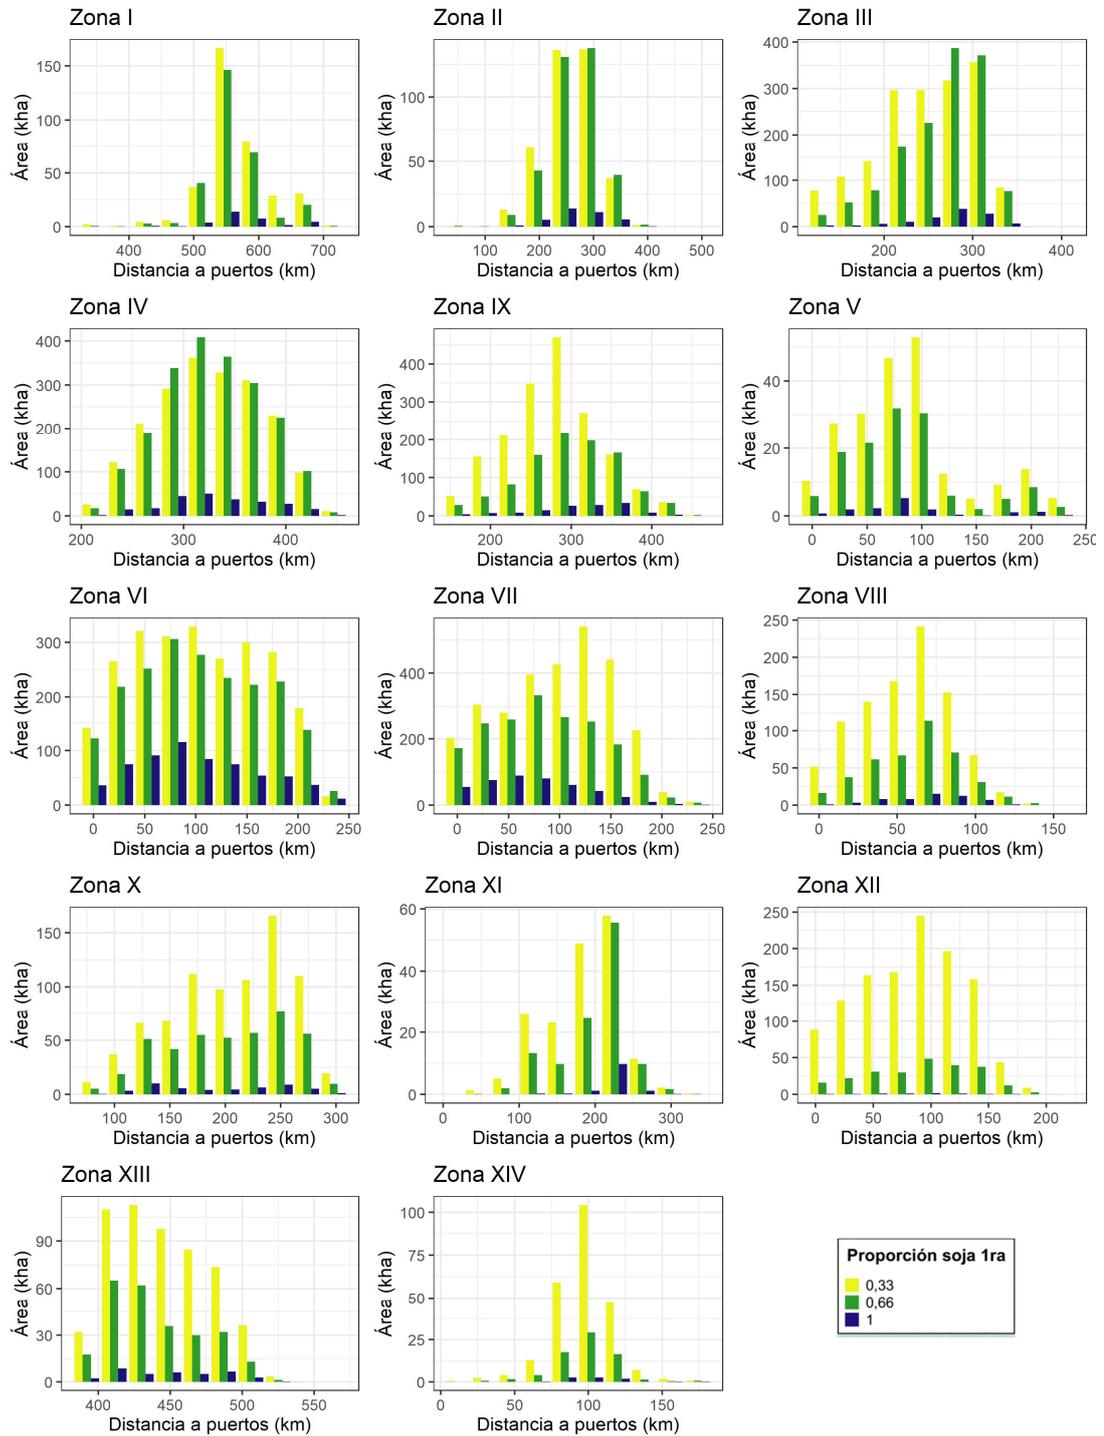


Figura A.5.1. Área de casos con diferente proporción de soja de primera durante las tres campañas agrícolas analizadas a lo largo de un gradiente de distancia a puertos, para 14 zonas agrícolas del Mapa Nacional de Cultivos (de Abelleira et al. 2019).