

Uso de suelo agrícola en la zona central de Córdoba: análisis de datos espaciales multisensor para su estudio y gestión

Por *Soraya Violini*

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

**MAGISTER EN APLICACIONES ESPACIALES DE ALERTA Y RESPUESTA TEMPRANA A
EMERGENCIAS**

UNIVERSIDAD NACIONAL DE CÓRDOBA

Junio, 2016

©IG - CONAE/UNC 2016

©FaMAF - UNC 2016

Directora: *Mgter. Mónica Bocco*
Co-Directora: *Mgter. Sofía Lanfri*
Asesor Técnico: *Lic. José Pasapera*



Uso de suelo agrícola en la zona central de Córdoba: análisis de datos espaciales multisensor para su estudio y gestión se distribuye bajo una [Licencia Creative Commons Atribución 2.5 Argentina](#)

*A los hermanos que me dio esta maestría, porque...
"siempre estarán en mí esos buenos momentos
que pasamos... no importa donde este...
siempre seras mi amigo no importa nada mas..."*

*A mi mamá, mi papá y mi hermana...
A mis amores, Tomás y Maitena...
...que siempre fueron y serán mi hogar
A Fabio, mi compañero de vida*

Agradecimientos

Agradezco a la Universidad Nacional de Córdoba y la CONAE por abrir sus puertas para mí y haberme permitido crecer. A la gente del CUSS, en especial a Mayco a quién no conozco personalmente pero me orientó y ayudó con los pedidos y reclamos de imágenes para esta tesis. A mi tribunal, María Laura Nores, Gustavo Ovando y Marc Thibeault por su tiempo y disposición.

Agradezco a toda la gente que forma parte del Instituto Gulich por haberme hecho sentir en casa. A los profes de la Maestría por tanta enseñanza desinteresada (solo los grande pueden hacerlo). Gracias al EURAC y a mi tutora en Italia, Claudia Notarnicola por haberme brindado su tiempo, sus conocimientos y su valiosa ayuda en todo momento.

Gracias a los MAEARTES con los que me cruce en este tiempo, en especial a aquellos con los que compartimos buenos momentos. A Marcelo Scavuzzo y Gabriel Platzeck por esta oportunidad, por ser tan GRANDES personas y MAESTROS. A mis queridas directoras, Moni y Sofi, un gran GRACIAS por la paciencia, las enseñanzas, tantos momentos compartidos y, sobre todo, por haber confiado en mí y por haberme alentado todo el tiempo. A Pichu, que también es parte de mi tesis, gracias por enseñarme todo y bancarme en las preguntas más tontas (sobre todo, por soportarme).

Un especial GRACIAS a los LEONES, por compartir sus conocimientos, el trabajo grupal, el intercambio cultural, el apoyo y, sobre todo, por el aguante y la amistad. Lo pase maravillosamente, son la mejor parte de esta increíble experiencia.

A mi FAMILIA por el apoyo incondicional en todo momento y lugar, les estaré enormemente agradecida siempre.

*"Gracias a la vida que me ha dado tanto.
Me dio dos luceros que, cuando los abro, perfecto distingo el negro del blanco,
y en el alto cielo su fondo estrellado, y en las multitudes AQUELLOS que amo."
Violeta Parra.*

Resumen

La sustentabilidad de los ecosistemas y los recursos y servicios que estos proporcionan, requieren que se comprendan a fondo los procesos de cambio de usos de suelo y sus efectos, ya que estos pueden llevar a la pérdida de capa superficial del suelo por erosión hídrica o eólica, inundaciones, pérdida de productividad, etc. El conocimiento de la distribución y superficie sembrada de cultivos agrícolas es indispensable para la planificación de políticas, para definir las bases de ordenamiento territorial y para productores en la toma de decisiones. La presente tesis, tiene como objetivo principal la identificación de cultivos de verano a través del uso de imágenes satelitales ópticas y de radar, en el centro de la provincia de Córdoba. Se utilizaron imágenes procesadas y calibradas de los sensores SPOT, Landsat y COSMO SkyMed, a las cuales se les realizó un análisis exploratorio de los datos para el conocimiento de la estructura de los mismos. Para todas las imágenes, se presentan las firmas espectrales y sus variabilidades en las longitudes de ondas del espectro visible y del infrarrojo como una primera aproximación que permita inferir el tipo de cobertura de suelo y, en los cultivos, su comportamiento y estadios fenológicos. Para la clasificación (tipo de cobertura de suelo, tipo de cultivo, etapa de desarrollo, etc) se estudiaron y aplicaron algoritmos de redes neuronales y se modelaron datos radar mediante el método de distancia estocástica de Hellinger. Se obtuvieron muy buenos resultados con imágenes ópticas, identificando cada cultivo en sus diversos estadios fenológicos con todos los métodos utilizados. A partir de imágenes provenientes de sensores SAR, se identificaron diferencias estadísticas y estocásticas, aunque los resultados en polarizaciones VV y HH no mostraron una clasificación estadísticamente válida para el área de estudio.

Palabras claves: Agricultura, NDVI, Redes Neuronales, COSMO SkyMed, SAR, Imágenes Ópticas.

Abstract

The ecosystems sustainability and the resources and services they provide, require to have a deep understanding about the processes of change of land use and its effects, these can lead to the loss of topsoil by wind or water erosion, floods, loss of productivity, etc. The knowledge of the distribution and amount of cultivated area is indispensable for policy planning, to define the basis for zoning and for decision makers and producers. This thesis, has as its main objective the identification of summer crops through the use of optical and radar satellite images in the center of the province of Cordoba. Processed and calibrated images from SPOT , Landsat and COSMO Skymed sensors were used, which were performed an exploratory analysis of the data in order to understand the structure of these images. For all images, the spectral signatures and their variability in the wavelengths of the visible spectrum and infrared were presented, as a first approximation that allows us to infer the type of land cover and, in the crops, their behavior and phenological stage. For classification (type of soil coverage, crop type, stage of development, etc) were studied and implemented algorithms of neural networks and radar data were modeled using the method Hellinger stochastic distance. Very good results with optical images were obtained, identifying each crop in its different phenological stages with all the methods used. From SAR sensor images, statistics and stochastic differences were identified, although the results in VV and HH polarizations showed no statistically valid classification for the study area.

Keywords: Agriculture, NDVI, Neural Net, COSMO SkyMed, SAR, Optical Images.

Índice general

1. Introducción	1
1.1. Objetivo general	4
1.2. Objetivos específicos	4
1.3. Estructura general del trabajo	5
2. Área de Estudio	7
2.1. Caracterización ambiental	7
2.1.1. Geología	9
2.1.2. Clima	9
2.2. Aptitud agrícola	10
2.3. Uso de suelo actual	12
3. Materiales y Métodos	15
3.1. Imágenes ópticas	15
3.1.1. Imágenes SPOT	16
3.1.2. Imágenes Landsat	18
3.2. Imágenes SAR	20
3.2.1. COSMO SkyMed	21
3.3. Modelo Digital de Elevación del Terreno	23

3.4. Datos de campo	24
3.5. Pre-procesamiento de imágenes	25
3.5.1. SPOT 5 y Landsat 8	26
3.5.2. SAR COSMO SkyMed	27
3.5.3. Co-registro de imágenes	28
3.6. Análisis exploratorio de los datos	29
3.6.1. Selección de regiones de interés	29
3.6.2. Estadística descriptiva y test de hipótesis de la distribución de datos	30
3.7. Análisis de la vegetación	31
3.7.1. Firmas espectrales	31
3.7.2. Índice de Vegetación de Diferencia Normalizada	31
3.8. Identificación y clasificación de coberturas	32
3.8.1. Relación entre datos ópticos y radar	33
3.8.2. Redes neuronales	33
3.8.3. Distancias estocásticas	38
4. Resultados	41
4.1. Pre-procesamiento de imágenes	41
4.1.1. SAR COSMO SkyMed	41
4.2. Análisis de datos	42
4.2.1. Distribución de datos y estadística descriptiva	42
4.3. Análisis de la vegetación	49
4.3.1. Firmas espectrales	49
4.3.2. Índice de Vegetación de Diferencia Normalizada	54
4.4. Identificación y clasificación de coberturas	57

4.4.1. Relación entre datos ópticos y radar	57
4.4.2. Redes neuronales	58
4.4.3. Distancia estocástica de Hellinger	71
5. Conclusiones	75

Índice de figuras

2.1. Ubicación del área de estudio sobre un recorte de una imagen de Google Earth Plus (arriba) y una imagen SPOT 5 (abajo) en la región central de la provincia de Córdoba, Argentina.	8
2.2. Superposición del perímetro de imágenes Landsat 8, SPOT 5 y COSMO SkyMed adquiridas para el área de estudio sobre un recorte de una imagen de Google Earth Plus.	8
3.1. Espectro electromagnético: energía radiante en función de su longitud de onda y frecuencia. Imagen extraída de Olaya, 2011.	15
3.2. Niveles de procesamiento de COSMO SkyMed. Imagen extraída de COSMO-SkyMed SAR Products Handbook.	22
3.3. Resolución espacial de los modos de adquisición del sensor COSMO SkyMed. Imagen extraída de e-GEOS.	22
3.4. ROIs de lotes muestreados a campo superpuestos en una imagen satelital SPOT 5, utilizados para el entrenamiento de los clasificadores aplicados.	29
3.5. Fotografías correspondientes al borde del Lote 9.	30
3.6. Firma espectral de la vegetación sana. Imagen extraída de Chuvieco, 1996.	32
3.7. Estructura general de una red neuronal. Imagen basada en Bocco, 2007.	34
4.1. Imágenes resultantes de aplicar una serie de herramientas de preprocesamiento para el tratamiento y formación de la imagen final SAR.	41
4.2. Imagen SAR final, resultante del preprocesamiento, en valores de intensidad y georeferenciada.	42
4.3. Box-plot de reflectancias de lotes seleccionados para distintas fechas y tipos de rastrojos y cultivos en imágenes SPOT 5 y Landsat 8.	44

4.4. Box-plot de lotes seleccionados para distintas fechas y tipos de rastrojos y cultivos en imágenes COSMO SkyMed.	46
4.5. Firmas espectrales de rastrojos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 18 de octubre de 2013.	50
4.6. Firmas espectrales para rastrojos con cultivos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 30 de diciembre de 2013.	51
4.7. Firmas espectrales para cultivos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 22 de marzo de 2014.	53
4.8. Evolución del NDVI en la campaña agrícola 2013-2014, desde octubre a abril, en el departamento Río Segundo, Córdoba.	55
4.9. Evolución de valores medios de NDVI temporal (octubre-abril) para todos los lotes con cultivo de maíz.	56
4.10. Evolución de valores medios de NDVI temporal (octubre-abril) para todos los lotes con cultivo de soja.	57
4.11. Clasificación de la imagen SPOT 5 de octubre de 2013, anterior a la siembra de cultivos de grano grueso.	59
4.12. Clasificación de las imágenes SPOT 5 y Landsat 8 del 28 y 30 de diciembre de 2013, posterior a la siembra de cultivos de grano grueso.	61
4.13. Clasificación de las imágenes SPOT 5 y Landsat 8 de los meses de enero y marzo de 2014, en pleno desarrollo de los cultivos.	63
4.14. Clasificación de la imagen Landsat 8 de abril de 2014, con avanzado estado fenológico de los cultivos y comienzo de la cosecha.	64
4.15. Clasificación temporal de imágenes COSMO SkyMed con ENVI.	67
4.16. Clasificación temporal de 6 imágenes COSMO SkyMed en polarización VV con R.	68
4.17. Clasificación con RN de imágenes COSMO SkyMed del área de estudio y bandas del rojo e infrarrojo cercano de imagen SPOT 5 del 1 de marzo.	70
4.18. Distancia de retrodispersión media y diferencia absoluta entre medias de NDVI entre lotes de maíz y soja.	73
5.1. Box-plot lotes relevados a campo para distintas fechas y tipos de rastrojos y cultivos en imágenes SPOT 5 y Landsat 8.	81

5.2. Box-plot de lotes revelados a campo para distintas fechas y tipos de rastrojos y cultivos en imágenes COSMO SkyMed. 83

Índice de tablas

3.1. Características del sensor SPOT 5. Imagen extraída de SPOT Image, 2010	17
3.2. Fechas y características de imágenes SPOT 5 utilizadas en el presente estudio	18
3.3. Sensores y características de bandas de Landsat 8. Imagen extraída de USGS, 2013. . .	19
3.4. Fechas y características de imágenes Landsat 8 utilizadas en el presente estudio. . . .	20
3.5. Características técnicas de imágenes SAR COSMO SkyMed. Imagen extraída de e-GEOS.	22
3.6. Fechas y características de imágenes COSMO SkyMed utilizadas en el presente estudio.	23
3.7. Fechas de muestreos en campo y de imágenes COSMO SkyMed, SPOT 5 y Landsat 8.	24
3.8. Datos de muestreos a campo para la zona en estudio para el 13 de marzo del 2014. . .	25
3.9. Datos de muestreo a campo para las zonas de Bell Ville y Monte Buey en lotes con rastrojos y cultivos de maíz y soja, para fechas de lectura con espectroradiómetro. . .	25
3.10. Parámetros para el co-registro de imágenes ópticas y radar.	28
3.11. Medias y desvíos estándares de los valores cuadráticos medios (RMS) del co-registro de imágenes de los satélites COSMO SkyMed, SPOT 5 y Landsat 8.	29
3.12. Configuraciones de prueba para clasificación con el algoritmo de redes neuronales de ENVI para la imagen SPOT 5 del 12 de marzo.	37
4.1. Lotes con tipos de rastrojos y cultivos seleccionados como representativos en la zona de estudio.	42
4.2. Resultados de test de normalidad de Kolmogorov-Smirnov (estadístico D y p-valor) para las imágenes (a) SPOT 5 y (b) Landsat 8.	47

4.3. Resultados de test de distribución Gamma de Kolmogorov-Smirnov (estadístico D y p-valor) para imágenes COSMO SkyMed.	49
4.4. Datos de campo de muestreo y NDVI del mes de diciembre en la zona de Bell Ville y en el área de estudio para lotes con cultivo de maíz.	52
4.5. Datos de campo de muestreo y NDVI del mes de marzo en la zona de Monte Buey y en el área de estudio, para lotes con cultivo de (a) maíz y (b) soja.	53
4.6. Matrices de precisión de las clasificaciones para distintas imágenes.	65
4.7. Porcentaje de píxeles bien clasificados y clasificados por omisión en cada clase con algoritmo de Redes Neuronales en R.	68
4.8. Exactitud global y Coeficiente Kappa de cada casificación de COSMO SkyMed y SPOT 5.	70
4.9. Porcentaje de píxeles bien clasificados en cada clase y clase con más píxeles por omisión, en clasificaciones de distintas combinaciones de imágenes COSMO SkyMed y bandas del rojo e infrarrojo cercano y de la imagen SPOT 5 del 1 de marzo.	71
4.10. Distancias de valores de retrodispersión entre cuatro lotes con cultivos de maíz en polarización VV y HH; medias y desvíos estándares de esas distancias.	72
4.11. Distancias de valores de retrodispersión entre cuatro lotes con cultivos de soja en polarización VV y HH, medias y desvíos estándares de esas distancias.	72
4.12. Distancias de valores de retrodispersión entre lotes con cultivos de maíz y soja en polarización VV y HH; medias y desvíos estándares de esas distancias.	73
5.1. Datos relevados a campo en fechas cercanas a las imágenes ópticas.	79
5.2. Resúmenes de estadística descriptiva de imágenes ópticas para lotes y fechas seleccionadas para presentar el estudio.	82
5.3. Estadística descriptiva correspondiente a imágenes COSMO SkyMed de lotes seleccionados	84
5.4. Resultados de test de distribución normal de Shapiro-Wilk(estadístico D y p-valor) para imágenes COSMO SkyMed.	85
5.5. Proporción de pixeles clasificados para cada clase en imagen óptica.	87

Capítulo 1

Introducción

El uso del suelo está inherentemente ligado con la sustentabilidad del uso de los recursos naturales. La forma e intensidad en que se modifica la cubierta vegetal determina la persistencia de los ecosistemas y, por ende, de los recursos y servicios que éstos proporcionan. Es fundamental, por tanto, entender en detalle los procesos de cambio de uso del suelo y sus efectos [1]. A través del tiempo, el hombre fue transformando los ecosistemas naturales en ecosistemas de producción mediante la incorporación de energía fósil y la eliminación de componentes biológicos [2]. De esta manera, los planteos productivos se concentraron en pocos cultivos de alta productividad y homogeneidad genética, maximizando la producción y la rentabilidad, y simplificando el manejo [3], haciendo posible que los rendimientos aumentaran en la misma proporción que la población [4]. Esta búsqueda de aumento de rindes productivos y de beneficios económicos llevó, constantemente, a una expansión de la agricultura sobre tierras naturales, boscosas y de pastoreo y a una intensificación en el uso de insumos [5], haciendo cada vez más necesario el conocimiento de la distribución y superficie sembrada con cultivos agrícolas para planificar políticas agrarias y definir bases de ordenamiento territorial rural, para investigadores en la construcción de modelos de funcionamiento ecosistémico y para productores en la toma de decisiones [6].

Tradicionalmente, estos datos fueron obtenidos de censos agropecuarios, realizados en períodos de tiempo muy espaciados, o de estudios realizados a campo, que resultaban muy costosos y que no abarcaban grandes áreas [7]. Sin embargo, en los últimos años, el avance de la tecnología de sensores remotos, permitió la realización de estudios multitemporales de grandes superficies a partir del uso de imágenes satelitales [8]. Esto, integrado a sistemas de información geográfica y la aplicación de tecnología (control de la erosión, la construcción de terrazas, la siembra directa, el manejo balanceado de nutrientes y su reposición, la rotación de cultivos para prevenir el deterioro de la materia orgánica de los suelos y la agricultura de precisión) lleva, a la mejora de los rendimientos agrícolas sin deteriorar los recursos naturales [9]. Uno de los objetivos principales del empleo de imágenes satelitales es el logro de la identificación y clasificación de coberturas. La capacidad de realizarlo abre la posibilidad de conocer la extensión y ubicación de cultivos, suelos o centros poblados y, mediante la comparación de imágenes de épocas distintas, advertir los cambios que se producen. Las estrategias a seguir para la obtención de estos mapas son numerosas y comprenden la selección del tipo de sensor, el método de clasificación (supervisado, no supervisado o mixto), el algoritmo (paramétrico o no paramétrico), los conjuntos de bandas y/o combinaciones de ellas y el número de imágenes (clasificaciones unitemporales o multitemporales) [10], [11].

Los sensores remotos, recogen datos de puntos situados a una distancia del objeto de interés [12], reconociendo características de la superficie terrestre y sus fenómenos, basándose en que los materiales tienen una respuesta espectral propia según sus propiedades físicas y el flujo de energía reflejada o emitida por ellos [13]. Las técnicas de teledetección, según el origen de la señal utilizada, se pueden agrupar en métodos pasivos y activos, los primeros, donde la fuente de energía es el Sol o la Tierra, involucra a los sensores ópticos y, los segundos, que generan su propia energía corresponden a los sensores de radar [14], ambos utilizados en éste estudio. Estos sensores, además, se diferencian en la región del espectro en la que detectan la señal electromagnética, que van desde longitudes de onda visibles, pasando por el infrarrojo (satélites ópticos) hasta las microondas (satélites radar). De esta forma, los métodos que utilizan cada uno para diferenciar distintos objetos y la forma en que los píxeles se agrupan, difieren de uno a otro. El conocimiento de las firmas espectrales es fundamental en teledetección, no sólo para identificar estos objetos sino para elegir las bandas más apropiadas y el sensor más conveniente para diferenciar las principales coberturas de la superficie terrestre: vegetación, suelo y agua [15]. En el caso de la vegetación, las propiedades espectrales cambian según la época del año y las fases de crecimiento [16]. La vegetación sana, tiene una reflectividad baja en el visible aunque con un pico en el color verde debido a la clorofila, una muy alta en el infrarrojo cercano debido a la escasa absorción de energía y en el infrarrojo medio hay una disminución especialmente importante en aquellas longitudes de onda en las que el agua de la planta absorbe la energía. La vegetación enferma, presenta una disminución de la reflectividad en las bandas infrarrojas y un incremento en el rojo y azul.

Numerosos trabajos se han realizado con la finalidad de obtener, a partir de imágenes satelitales, mapas y describir cultivos agrícolas. En este sentido, el Índice de Vegetación de la Diferencia Normalizada (NDVI) propuesto por Rouse (1974) ha sido extensamente utilizado ([17], [18]), y resultó un buen indicador de densidad de cobertura y del crecimiento integral del cultivo [19]. Existen también otros índices para describir características y estados de los cultivos agrícolas a partir de imágenes satelitales, entre los más comunes están la Razón Simple (SR) que se obtiene dividiendo las reflectancias infrarroja cercana y roja y el Índice de Vegetación Perpendicular (PVI), desarrollado por Richardson y Wiegand (1977) [20], que permite diferenciar información de la vegetación y del suelo.

Cuando el objetivo es realizar una clasificación del uso de suelo agrícola, distinguiendo distintos cultivos, fechas de siembra, estado fenológico, tecnología utilizada, etc. se presenta como excelente posibilidad la aplicación de teledetección. Existen y se han reportado un sinnúmero de metodologías para su aplicación. Los métodos de clasificación más utilizados son supervisados y no supervisados ([21], [22], [23], [24], [25], [26], [27], [28], entre otros), los cuales como exponen los autores citados presentan ventajas y desventajas.

Los métodos supervisados son frecuentemente utilizados cuando se tiene cierto conocimiento previo del área de estudio [29], en general los algoritmos elegidos extrapolan características espectrales para otras regiones de la imagen realizando así la clasificación [30]; por el contrario, los no supervisados no cuentan con información previa sobre la escena y el análisis apunta a la discriminación de grupos de objetos que permitan establecer las distintas clases [31]. Entre los métodos supervisados, en los últimos tiempos, adquirió gran importancia el uso de Redes Neuronales (RN) que han demostrado excelentes resultados, superando las limitaciones de los algoritmos paramétricos a diferentes escalas de mediciones y unidades. Las redes neuronales artificiales fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de unidades llamadas neuronas o nodos, interconectadas en un arreglo y organizado en capas. Las RN tienen la capacidad de computar, procesar, predecir y clasificar datos; a su vez permiten ajustar una respuesta aún con problemas

complejos y no-lineales. Consisten en un sistema de neuronas interconectadas que proporcionan un resultado a través de funciones matemáticas [32].

Para Córdoba, Argentina, Bocco et al. (2007) [27] utilizando imágenes MODIS y RN, clasificaron el suelo de uso agrícola en las categorías: soja (*Glycine max (L.) Merrill*), maíz (*Zea mays L.*) y suelo desnudo. Guerschman et al. (2003) [33] utilizaron cuatro imágenes Landsat TM de la misma estación de crecimiento para clasificar uso de suelo en una región de la provincia de Buenos Aires, donde se presenta una mezcla de cultivos anuales con pasturas perennes (implantadas y nativas). Para otros países se pueden citar los trabajos de Sandoval et al. (2014) [34], quienes a partir del estudio de espacios de color de las imágenes satelitales y aplicando RN (más precisamente Funciones de Base Radial) clasificaron cultivos para México. Wardlow et al. (2007) [35] investigaron la aplicabilidad de datos MODIS para clasificar uso/cobertura del suelo en cultivos agrícolas en las planicies centrales de EEUU. Más atrás en el tiempo, Martínez-Casasnovas et al. (2005) [36] quienes utilizando clasificaciones supervisadas de imágenes Landsat realizaron mapas de cultivos y rotaciones para el período 1993-2000, en una región de España.

Ding and Chen (2010) [7] mostraron que combinando imágenes ópticas con las provenientes de radares se puede obtener información precisa y detallada de los cambios de la vegetación y su productividad y, además, monitorear a distintas escalas. La fusión de datos multi-sensor mejora de la precisión global de la clasificación y la reducción de la incertidumbre de datos provenientes de una única fuente.

Las longitudes de onda del radar, microondas, pueden penetrar más profundo en la vegetación que las ondas ópticas, adquiriendo información superficial de la vegetación y de la estructura debajo de las mismas. En particular, el radar COSMO-SkyMed (CSM) se caracteriza por tener cobertura global y en todas las condiciones climáticas, alta resolución espacial, exactitud y calidad de imágenes, alta resolución temporal y capacidad para interferometría y polarimetría entre otras [37]. Este Radar de Apertura Sintética (SAR) permite obtener imágenes con una muy buena resolución espacial y temporal que posibilitan el análisis y el modelado matemático de los datos [38], sintetizar las imágenes para todas las posibles polarizaciones (simples, HH o VV o HV o VH; dual HH y HV, VV y VH, o HH y VV; completa, HH, VV, HV, y VH o polarimétricas, usa las cuatro polarizaciones), facilitando la extracción de información de ellas.

Las imágenes del CSM presentan un nuevo desafío para la modelación de variables agronómicas ya que el pre-procesamiento y su interpretación son más complejos que en los sistemas ópticos, debido a la presencia de ruidos en la imagen que es indispensable filtrar a fin de su interpretación [38]. A nivel mundial, entre los primeros trabajos de aplicación de imágenes SAR se encuentra el de Chen et al (1996) [39] quienes determinaron cobertura de suelo, distinguiendo bosques, agua, el suelo desnudo y ocho tipos de cultivos analizando la respuesta del radar según estados de frecuencia y polarización, a partir de una red neuronal de aprendizaje dinámico. Capodici et al. (2013) [40] presentaron mapas de NDVI e índice de área foliar (IAF) de maíz y alfalfa (*Medicago sativa*), a partir de imágenes CSM y realizaron un análisis de correlación basado en ángulo de incidencia, resolución y modo de polarización, para regiones de Italia. Combinando CSM, *Environmental Satellite* (ENVISAT), *Advanced Synthetic Aperture Radar* (ASAR) y *Phased Array L-band Synthetic Aperture Radar* (ALOS PALSAR) con imágenes MODIS, Wang et al. (2013) [41] monitorearon pasturas en Australia. Kussul et al. (2014) [42] a partir de imágenes SAR clasificaron soja, maíz, remolacha azucarera y girasol, para Ucrania utilizando RN y árboles de decisión como metodología de trabajo. Para Argentina no se encuentran aún aplicaciones de SAR para clasificación de cultivos de interés. En particular, utilizando

imágenes del CSM. Soria et al. (2012) [43], analizaron la respuesta espectral de diferentes coberturas de caña de azúcar (*Saccharum officinarum*), si bien concluyeron que los datos analizados en Tucumán (Argentina) no permitían discriminar netamente distintas coberturas.

Este estudio pretende identificar, clasificar y analizar el uso de suelo en la región central de la provincia de Córdoba, utilizando imágenes ópticas y radar. El área de estudio, se encuentra en la llanura central de Argentina y presenta un relieve de lomas muy extendidas, casi planas. Todos los suelos del área se clasifican como Haplustol éntico, con textura limosa gruesa, mineralogía mixta, de un régimen térmico de temperatura del suelo [44]. El clima en el área de estudio se clasifica como seco subhúmedo. En esta zona los dos cultivos predominantes, en verano, son soja y maíz. En Argentina, por superficie sembrada y réditos económicos, el cultivo de soja [45] es el más importante. En la campaña 2011/12 se sembraron a nivel nacional 18.670.000 ha y en Córdoba 5.014.000 ha (27 % del total nacional). Por otro lado, el cultivo de maíz [46] es el segundo en importancia en el país, con un área total sembrada superior a 5.000.000 ha en la misma campaña [47].

1.1. Objetivo general

Clasificar uso de suelo agrícola y caracterizar cultivos mediante el análisis de datos satelitales ópticos y radar en el área central de la provincia de Córdoba.

1.2. Objetivos específicos

En el desarrollo del trabajo de tesis se focalizará en los siguientes objetivos específicos:

1. Obtener firmas espectrales en el rango del visible, de los cultivos presentes en el área de estudio, diferenciando sus respuestas espectrales según especies y etapas de crecimiento de los mismos.
2. Analizar estadísticamente los datos ópticos y radar de las imágenes correspondientes al área de estudio.
3. Clasificar cultivos con imágenes satelitales ópticas, implementando un algoritmo basado en redes neuronales.
4. Clasificar cultivos con imágenes SAR, COSMO SkyMed.
5. Analizar la fusión de datos multisensor con el fin de aumentar la precisión de las clasificaciones y comparar el desempeño de cada uno individualmente.
6. Identificar diferencias entre cultivos, sus estados fenológicos y su comportamiento temporal aplicando el índice de vegetación normalizado.
7. Evaluar la relación entre los perfiles temporales de NDVI de los distintos cultivos y la retrodispersión radar.

1.3. Estructura general del trabajo

Esta tesis, fue organizada en 5 capítulos:

- **Capítulo I: Introducción** se describen los conceptos básicos de uso de suelo, teledetección, sensores remotos y metodologías generales de clasificación de imágenes.
- **Capítulo II: Área de Estudio** se describe el área de estudio, ambiental y productivamente y se presentan datos sobre uso actual del suelo en la zona, así como antecedentes en el tema.
- **Capítulo III: Materiales y Métodos** se introduce, por un lado, a las imágenes satelitales SPOT 5, Landsat 8 y COSMO SkyMed: sus resoluciones, modos de adquisición, niveles de procesamiento y otras características generales y diferencias entre ellas, además de las específicas de las adquisiciones obtenidas para el desarrollo de este estudio. Asimismo, se detallan el Modelo Digital de Elevación del Terreno (DEM) utilizado y los datos de campo obtenidos para validación de la información satelital. Por otro lado, en la metodología, se desarrollan y definen conceptos de pre-procesamiento de imágenes ópticas y radar, análisis de datos, de vegetación y clasificación.
- **Capítulo IV: Resultados** se presentan, analizan y discuten los resultados obtenidos para la clasificación de cultivos, métodos y tipo de sensor presentados previamente, así también como la relación y comportamiento del índice de vegetación con diversos aspectos del ambiente y de los cultivos.
- **Capítulo V: Conclusiones** se plantean las conclusiones y observaciones a los objetivos planteados y consideraciones futuras.

Por último, se presentan una serie de Anexos de tablas, gráficos y matrices.

Capítulo 2

Área de Estudio

2.1. Caracterización ambiental

La provincia de Córdoba se ubica en el centro de la República Argentina, entre los 29° 30' y los 35° de latitud sur y los 61° 47' y 61° 46' de longitud oeste. Limita al norte con la provincia de Santiago del Estero, al este con las provincias de Santa Fe y Buenos Aires, al sur con esta última y con la provincia de La Pampa y al oeste colinda con las provincias de San Luis, La Rioja y Catamarca. Córdoba ocupa una superficie de 165.321 km², lo que representa el 4,4 % del territorio nacional y el 5,9 % de la Argentina continental.

La Figura 2.1 muestra la ubicación del área de estudio dentro de la provincia de Córdoba, la cual se sitúa en la llanura central, departamento Río Segundo y comprende la zona rural de Pilar, Río Segundo y Laguna Larga, entre los 200 y 600 msnm. Constituye un plano inclinado hacia el este, cubierto por una potente acumulación de sedimentos eólicos franco limosos. Está surcada por cursos de agua que nacen en las sierras donde exhiben importantes procesos de erosión vertical y lateral [48]. El área, es un cuadrado de aproximadamente 20 km de lado cuyas coordenadas son:

- Esquina superior izquierda: 31° 46,786' S; 63° 56,131' O
- Esquina inferior derecha: 31° 57,586' S; 63° 43,484' O

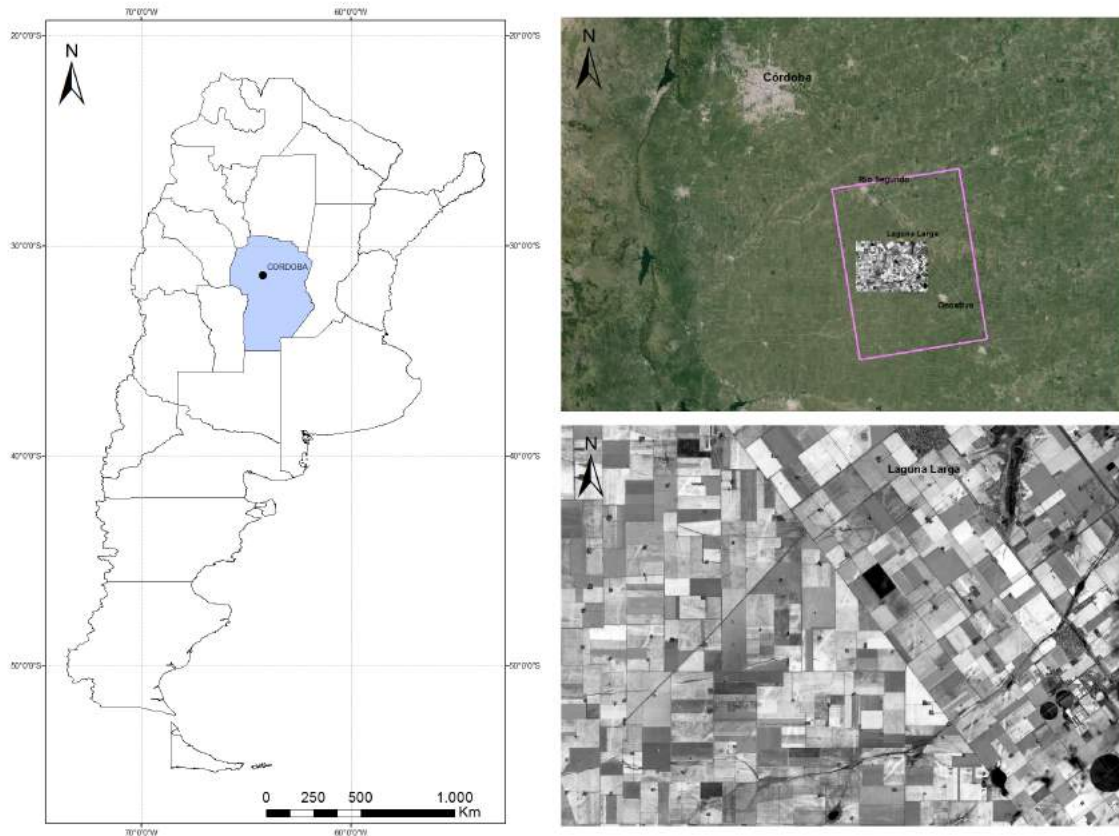


Figura 2.1: Ubicación del área de estudio sobre un recorte de una imagen de Google Earth Plus (arriba) y una imagen SPOT 5 (abajo) en la región central de la provincia de Córdoba, Argentina.

En la Figura 2.2 se muestra la superposición del área de la totalidad de las imágenes adquirida de cada uno de los sensores, Landsat 8, COSMO SkyMed y SPOT 5, para la zona de estudio.

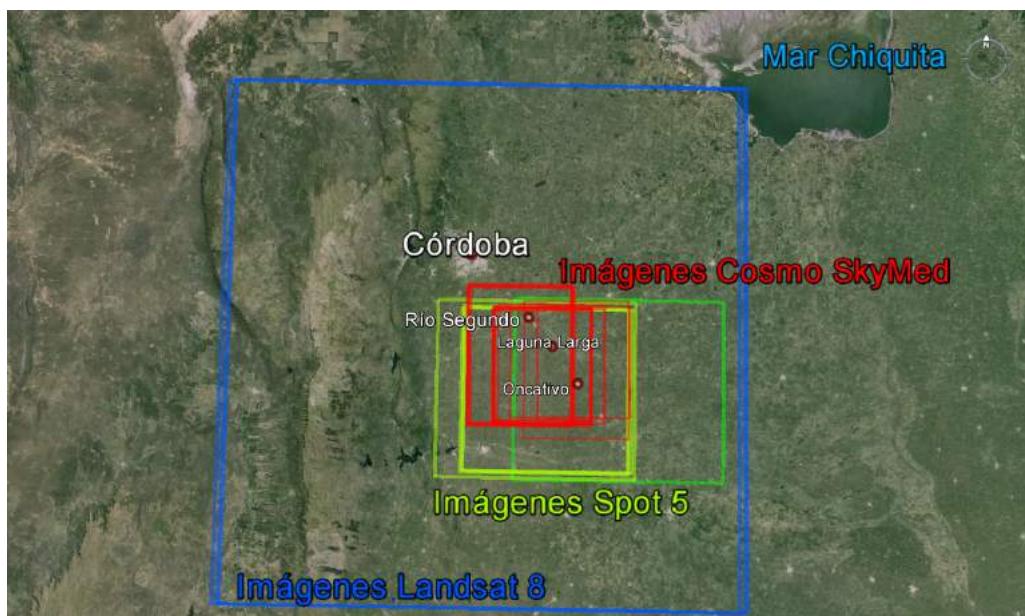


Figura 2.2: Superposición del perímetro de imágenes Landsat 8, SPOT 5 y COSMO SkyMed adquiridas para el área de estudio sobre un recorte de una imagen de Google Earth Plus.

2.1.1. Geología

La geología de la provincia presenta, en casi dos tercios de su territorio, áreas de llanura; incluida una parte de la pampa húmeda, una parte de la llanura chaqueña y los llanos occidentales; estando el resto ocupado por formaciones montañosas pertenecientes al sistema de las Sierras Pampeanas. Este sistema de Sierras, presentan tres tipos de relieves dominantes: los cordones serranos, dispuestos longitudinalmente en sentido dominante norte-sur, las planicies elevadas o "pampas" las depresiones interserranas o valles. Las características del relieve, junto con el clima, el material original y otros, hacen al tipo de suelo y la distribución de los mismos en el territorio de la provincia [49]. De acuerdo con el sistema americano *Soil Taxonomy* [50], la provincia de Córdoba se reconocen cuatro Ordenes de suelos: Aridisol, Entisol, Molisol y Alfisol, los cuales son definidos según su proceso de formación, indicados por la presencia o ausencia de importantes horizontes diagnósticos.

La zona de estudio, se encuentra en la subregión conocida como Pampa loésica Alta y está compuesta por suelos del Orden de los Molisoles, Gran Grupo Haplustol, Sub Grupo éntico (MNen). La característica principal de este Subgrupo es la presencia de un horizonte superficial oscuro, con moderado contenido de materia orgánica y bien estructurado (epipedón mólico), seguido de un horizonte de transición (AC) con escaso desarrollo y poco alterado, pasando gradualmente al material originario, constituyendo un suelo poco evolucionado, de características énticas. Presentan, por lo tanto, una secuencia de horizontes A, AC y C; siendo suelos bien a algo excesivamente drenados, vinculados a lomadas onduladas o suavemente onduladas, con la capa freática profunda que no afecta el perfil del suelo y desarrollados en condiciones climáticas de semiaridez (régimen ústico de humedad). Los materiales que dieron origen a estos suelos, constituyen sedimentos eólicos de granulometría variada, desde franco arenosos, francos a franco limosos [44].

2.1.2. Clima

La provincia se encuentra comprendida, en su totalidad, en la zona templada. La temperatura del aire y sus variaciones es la causa inicial de un gran número de fenómenos meteorológicos. Desde el punto de vista agronómico esa importancia aumenta pues todos los fenómenos fisiológicos de los cultivos están fuertemente influidos por la temperatura del aire. Las características del régimen térmico están determinadas por las temperaturas del mes más cálido, del mes más frío y su amplitud térmica anual [51]. Los valores térmicos del mes de enero (temperaturas estivales), se distribuyen en la provincia en un rango que oscila entre los 23,5°C, en el sur, hasta valores superiores a los 26°C, en la zona norte. Se destaca la acción del cordón serrano sobre la marcha de las isoterms, las cuales se dirigen hacia el norte para compensar latitudinalmente el efecto del relieve. Las temperaturas del mes de julio, evidencian un rango de valores que van desde los 8°C en el sur hasta los 11,5°C en el norte. La amplitud anual de la temperatura representa la variación de los meses extremos y las causas que la determinan. A pesar de tratarse de una provincia mediterránea, la temperatura no alcanza registros extremos y el rango o amplitud térmica anual no supera los 16°C en toda la provincia [52].

Las primeras heladas, comienzan a registrarse en la primera quincena de mayo en el sur o a mediados de junio en el norte de la provincia, mientras que las últimas se extienden hasta mediados de septiembre y mediados de agosto, respectivamente. Se establece así un período libre de heladas de unos 235 y 300 días, aproximadamente. En cuanto a las precipitaciones, las lluvias son abundantes desde mediada la primavera hasta mediado el otoño; el semestre frío, en cambio, acusa escasos milí-

metros. Se observa un gradiente este-oeste desde más de 900 mm en la porción oriental del territorio a menos de 600 mm en los límites con La Rioja.

La humedad del suelo, es de suma importancia para la actividad agrícola ya que está directamente relacionada al consumo de agua por las raíces de las plantas. La precipitación es uno de los elementos del clima que determina la cantidad y variabilidad de este factor. Además, la disponibilidad y el flujo de agua regulan la velocidad y desarrollo de la mayoría de los procesos edáficos. Los efectos de la precipitación sobre los cultivos varían según el estado vegetativo de la planta, época del año y características y humedad inicial del suelo [53]. Se ha comprobado que los rendimientos de los cultivos muestran una correlación más estrecha con la humedad del suelo y con los componentes del balance hídrico que con los mm de precipitación [51].

Por otro lado, uno de los principales componentes del balance hídrico lo constituye la evapotranspiración. En la provincia de Córdoba, la evapotranspiración potencial estimada por el método de Penman (1948) fluctúa entre los 880 y los 1080 mm anuales. La evapotranspiración real, estimada a través del balance hídrico, varía entre los 640 y los 800 mm anuales. Como resultado de la diferencia entre ambas evapotranspiraciones se obtiene a la deficiencia hídrica. Esta adquiere valores anuales de unos 80 mm en el área de Marcos Juárez y asciende hasta los 480 mm en Villa Dolores [44].

En la zona de estudio, el clima se caracteriza por un régimen térmico con una temperatura media anual de 16°C, una amplitud térmica de 14°C y un período libre de heladas de 265 días. Las precipitaciones promedio anuales son de 800 mm con un período lluvioso se extiende de octubre a marzo (580 mm), el cual representa el 80 % de las precipitaciones anuales. El déficit hídrico presenta una variación de 180 mm a 220 mm, de este a oeste [48].

2.2. Aptitud agrícola

Clasificación de uso del suelo

La clasificación de los suelos según su capacidad de uso y aptitud, sirve de base para un manejo más sustentable de los mismos. Las buenas prácticas agrícolas, tienen en cuenta las limitaciones de los suelos con el fin de evitar la erosión y escurrimiento, exceso de agua, pérdidas de fertilidad, etc. que no degraden el recurso y mantengan un equilibrio productivo [9].

En nuestro país, el Instituto Nacional de Tecnología Agropecuaria (INTA) [44], basa esta clasificación en el sistema utilizado por el Servicio de Conservación de Suelos de Estados Unidos (SCS, USDA), con algunas modificaciones. El sistema de clasificación se divide en ocho clases con aumentos progresivos de las limitaciones de los suelos para la utilización de actividades agrícolas, señaladas con números romanos. Las cuatro primeras clases incluyen los suelos aptos para cultivos.

- Clase I: requiere poco o ningún tratamiento de manejo o conservación especial.
- Clases II, III y IV: necesitan grados crecientes de cuidado y protección.

- Clases V a VII: por lo general, no son aptas para los cultivos y precisan cuidados progresivamente más intensos aún cuando se destinan a pasturas o a la forestación.
- Clase VIII: no tiene aplicación agrícola ni ganadera, sólo sirve para la recreación, para conservación de la fauna silvestre, provisión de agua o fines estéticos.

Las subclases informan sobre los tipos principales de limitaciones que afectan a las clases. Excepto la clase I, el resto admite una o dos de las cuatro subclases, definidas en el sistema utilizado y que se designan agregando las letras minúsculas 'e', 'w', 's' o 'c' a continuación del número de clase.

- Subclase 'e' -erosión- integrada por suelos en los que la susceptibilidad a la erosión es el problema o peligro dominante para su uso.
- Subclase 'w' -exceso de agua- constituida por suelos en los que dicho exceso es el riesgo o limitación dominante (drenaje pobre, humedad excesiva, capa de agua alta (freática o suspendida) y anegabilidad).
- Subclase 's' -limitaciones del suelo dentro de la zona radical- presentan problemas de escasa profundidad, baja capacidad de retención de humedad, salinidad o alcalinidad y bajo nivel de fertilidad, difíciles de corregir.
- Subclase 'c' -limitación climática- el clima es la mayor limitación.

En la clase I no hay subclases; sólo admite subgrupos basados en distintas condiciones naturales de drenaje e indicados por un número arábigo (I-1, I-2, I-1/2, I-1/3).

Índices de productividad

Nakama y Sobral [54] del Departamento de Evaluación de Tierras (INTA-CASTELAR) han desarrollado y puesto en práctica fórmulas para el cálculo del Índice de Productividad (IP) a partir del Sistema Paramétrico Multiplicativo propuesto por Riquier, Bramao y Cornet (1970), al que se han introducido una serie de modificaciones para adaptarlo a las distintas y variadas condiciones ecológicas e información básica disponible.

La determinación del IP tiene como objetivo establecer comparaciones entre las capacidades de producción de los distintos tipos de tierras presentes en un área, partido, región o provincia. Para implementar el mismo, se ha utilizado una regionalización climática del país, donde en cada una de las regiones tiene vigencia la misma metodología, pero pueden variar los parámetros considerados y las valoraciones asignadas. En esta regionalización, intervienen las siguientes variables climáticas y edafoclimáticas:

- Isolíneas de índice hídrico.
- Isotermas medias anuales.
- Regímenes de temperatura.

- Humedad de los suelos.

El valor del índice calculado se interpreta como una proporción del rendimiento máximo potencial de los cultivos más comunes de la región, ecotípicamente adaptados, bajo un determinado nivel de manejo. En otras palabras, el valor obtenido menos 100, corresponde al porcentaje de disminución en los rendimientos máximos debido a alguno de los efectos de una o más de las variables mencionadas anteriormente.

Por otro lado, esta determinación se realiza en dos etapas, primero se calcula el índice de productividad de cada unidad taxonómica (IPt) y, luego, a partir de los resultados de la anterior, y con la consideración de los porcentajes de participación areal de cada componente, se calculan los índices de productividad de las unidades cartográficas (IPc).

El área de estudio, se clasifica en aptitud de uso como Clase III, unidad compuesta por suelos de planos extendidos: Haplustol éntico, bueno a algo excesivamente drenado, profundos (más de 100 cm), franco limoso en superficie y subsuelo, bien provisto de materia orgánica, moderada capacidad de intercambio catiónico, con un IP de 68 y marcada limitación en su capacidad de retención de humedad [44].

2.3. Uso de suelo actual

En Argentina, en los últimos años existió un gran incremento de la producción de granos que estuvo marcada por la expansión de la frontera agrícola y el aumento de los rendimientos a partir de la incorporación de materiales genéticos de mayor potencial y estabilidad, la implementación de técnicas de manejo como la siembra directa y la fertilización, y el manejo integrado de plagas, enfermedades y malezas [55].

En el caso de Córdoba, desde el punto de vista de la capacidad de uso del suelo, la provincia tiene un tercio de superficie con tierras de neta aptitud agrícola (Clase I, II y III, 5,5 millones de hectáreas) y un 17 % de tierras consideradas marginalmente agrícolas (Clase IV, 2,7 millones de hectáreas) [56]. El total de hectáreas sembradas en la campaña 2013-2014 llegó a 8 millones de ha (aumentó en 2 millones aproximadamente, respecto del 2000-2001), con un gran aporte y aumento del área sembrada con soja [57], lo que indicaría que se están utilizando tierras marginales, modificando el uso de suelo.

Según datos oficiales del último censo agropecuario, durante la campaña agrícola 2006-2007 la producción de oleaginosas, cereales y forrajeras alcanzó casi 30 millones de toneladas de una gran variedad de granos gruesos y finos (girasol, maní, sorgo, avena, centeno, cebada, trigo, maíz, sorgo y arroz, entre otros), de los cuales, la soja y el maíz, fueron los principales cultivos [58].

Respecto del departamento de Río Segundo, que incluye el área de estudio, la superficie implantada total (entre cereales, oleaginosas, forrajeras, etc.) fue de medio millón de ha, según datos del Censo Nacional Agropecuario de 2008. De estas, alrededor de 75 mil ha fueron de maíz que, ocupó el segundo lugar entre los cereales de grano por detrás del trigo (más de 130 mil ha) y, de las oleaginosas, la soja de primera y segunda sumaron más de 285 mil ha. La producción total en este departamento

fueron 681 mil toneladas, 320 mil toneladas de maíz y 528 mil toneladas de soja, haciendo de éstos los principales cultivos de la zona [58].

En general, las practicas se dirigen a un monocultivo de soja lo que termina en una pérdida de nutrientes del suelo, bastante común en todo el territorio argentino [55]. La siembra directa es el sistema de labranza indicado para cualquier practica agrícola en la zona de estudio. Si hay efectos de erosión hídrica o alta susceptibilidad a ella, se debería sumarse a esta, un manejo a través de prácticas enfocadas a la conservación del suelo. Es imprescindible efectuar rotaciones de cereales y leguminosas, básicamente maíz-soja. Si la explotación es mixta se sugieren cuatro años de pastura base alfalfa y cuatro años de agricultura [56].

Capítulo 3

Materiales y Métodos

Materiales

3.1. Imágenes ópticas

La observación remota es posible gracias a la interacción de un flujo energético, radiación electromagnética, con elementos de la superficie de la Tierra [59]. Este flujo, presenta comportamientos que pueden explicarse por la teoría de Huygens/Maxwell, que la concibe como un haz ondulatorio y, la teoría de Plank/Einstein, que la considera como una sucesión de unidades discretas de energía, cuantos y fotones, con masa igual a cero. A partir de estas teorías, se puede definir a cualquier tipo de energía radiante en función de su longitud de onda y frecuencia organizadas en bandas que definen el espectro electromagnético (Figura 3.1) [10].




Figura 3.1: Espectro electromagnético: energía radiante en función de su longitud de onda y frecuencia. Imagen extraída de Olaya, 2011.

Independientemente de su procedencia, para toda radiación se dan tres fenómenos:

1. Absorción

2. Transmisión

3. Reflexión

Estos fenómenos se dan en distintas proporciones en función de las características del objeto y la radiación. En teledetección, sin embargo, la parte que nos interesa es la energía reflejada por los objetos de la superficie y la radiación infrarroja, que será la que llegue al sensor y se empleará para generar la imagen. Una imagen de varias bandas, contiene información sobre la intensidad de la radiación reflejada y emitida en distintos rangos del espectro [60].

Los sensores ópticos son sistemas pasivos que operan en rangos del espectro comprendidos en algunas zonas del visible e infrarrojo cercano (NIR), medio (SWIR), y térmico (TIR) [59], frecuencias que no siempre son registrables por el satélite debido a condiciones de cobertura de nubes, neblina, polvo, granizo o humo.

3.1.1. Imágenes SPOT

El programa SPOT (*Satellite Pour l'Observation de la Terre*) ha sido desarrollado por el Centro Nacional de Estudios Espaciales Frances (CNES), en colaboración con Bélgica y Suecia. La constelación SPOT provee imágenes ópticas de alta resolución y campo amplio desde 1986. La misma, esta formada por seis satélites y, se pretende completarla con un séptimo próximamente, para garantizar continuidad del servicio hasta el 2024, con órbita casi polar, circular, heliosincrónica y en fase, con una resolución temporal de 26 días y a una altitud de 822 km [61].

El satélite SPOT 5 fue lanzado en mayo de 2002 con la introducción del Súper-Modo, que permite la creación de una imagen con 2,5 m de resolución en el pancromático a partir de dos imágenes de 5 m adquiridas simultáneamente con un semi-píxel de desfase. Su combinación se realiza mediante técnicas avanzadas de tratamiento y restauración de imágenes. También cuenta con 5 m de resolución en el pancromático, 10 m en multiespectral y capacidades de adquisición de pares estereoscópicos mejorados gracias al instrumento ARE (Alta Resolución Estereoscópica) e incorpora VEGETATION-2, sucesor del VEGETATION-1 que llevaba a bordo el SPOT 4 [61].

Las imágenes ópticas SPOT, pueden adquirirse con los siguientes niveles de procesamiento [62]:

- Nivel 0: No se aplica el procesamiento Radiométrico ni Geométrico.
- Nivel 1A: Corrección radiométrica de distorsión debido a las diferencias en la sensibilidad de los detectores elementales de los instrumentos ópticos. Este nivel, está destinado a los usuarios que desean realizar sus propios procesamientos geométricos.
- Nivel 1B La corrección radiométrica es idéntica al nivel 1A. La corrección geométrica de los efectos sistemáticos (efectos panorámicos, curvatura y rotación de la Tierra) y las distorsiones internas de la imagen son corregidas para medir distancias, ángulos y superficies de áreas. Es un producto especialmente designado para la fotointerpretación y estudios temáticos.

- Nivel 2A: Corrección radiométrica idéntica al nivel 1A. Corrección Geométrica realizada en una proyección cartográfica estándar (UTM WGS84 por defecto) y no está basada en puntos de control.

Con un corredor de una amplitud de 60 km y una resolución que puede ir de 1,5 m a 20 m (Tabla 3.1), los productos SPOT constituyen una referencia cartográfica tanto a escala local como regional. Las mismas, son una fuente de información económica óptima para conocer, monitorear, prever y administrar los recursos y las actividades humanas en todo el planeta. Son herramientas de ayuda en la toma de decisiones en numerosas áreas: cartografía civil y militar, gestión de desastres naturales o tecnológicos, seguros, exploración de recursos naturales, ordenación del territorio, agricultura, ingeniería civil, protección del medio ambiente, vigilancia de espacios marítimos, sistemas de información geográfica, etc.

Tabla 3.1: Características del sensor SPOT 5. Imagen extraída de SPOT Image, 2010

Fecha de lanzamiento	3 de mayo del 2002
Vehículo utilizado	Ariane 4
Altitud de órbita	822 km
Inclinación de órbita	98,7° sincronización-solar
Velocidad	7,4 km/segundos - 26.640 Km/hora
Horario de cruce por el Ecuador	10:30 a.m. (nódulo en descenso)
Tiempo en órbita	101,4 minutos
Tiempo de regreso	2-3 días dependiendo en latitud
Escena	60 km x 60 km a 80 km a nadir
Exactitud métrica	<50-m de exactitud en posición horizontal
Digitalización	8 Bits
Resolución Espacial	Pan: 2,5 m de 2 x 5 m escenas Pan: 5 m (nadir) MS: 10 m (nadir) SWI: 20 m (nadir)
Bandas	Pan: 480 - 710 nm Verde: 500 - 590 nm Roja: 610 - 680 nm IR Cercano: 780 - 890 nm IR Onda Corta: 1.580 - 1.750 nm

A los fines de este trabajo, se utilizaron imágenes SPOT 5 del área en estudio, cedidas por la Comisión Nacional de Actividades Espaciales (CONAE) en el marco de la Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias dictada por el Instituto de Altos Estudios Mario Gulich de CONAE y la Facultad de Matemáticas, Astronomía y Física de la Universidad Nacional de Córdoba. Dichas imágenes, tienen una resolución espacial de 10 m, son multiespectrales y tienen un nivel de procesamiento 2A. En la Tabla 3.2 se detallan los archivos empleados:

Tabla 3.2: Fechas y características de imágenes SPOT 5 utilizadas en el presente estudio

Fecha	Número imagen
18/10/2013	SPOT5_HRG2_2013-10-18_13-37-07_J_685_414_S0_L2A
30/12/2013	SPOT5_HRG1_2013-12-30_13-29-02_J_686_414_S0_L2A
01/03/2014	SPOT5_HRG1_2014-03-01_13-52-17_J_685_414_S0_L2A
12/03/2014	SPOT5_HRG2_2014-03-12_13-39-57_J_685_414_S0_L2A
22/03/2014	SPOT5_HRG1_2014-03-22_13-47-04_J_685_414_S0_L2A

3.1.2. Imágenes Landsat

El Programa Landsat constituye, desde 1972, una serie de misiones de observación de la tierra por satélite, gestionado conjuntamente por la NASA y el Servicio Geológico de Estados Unidos (USGS). Landsat 8, es la octava edición de este programa y amplía, mejora y avanza en el registro de imágenes multiespectrales, manteniendo la misma calidad de sus siete predecesores (resolución temporal de 16 días, usando el mismo programa de adquisición de Landsat 5) [63]. Este sistema está compuesto de dos grandes segmentos:

- El observatorio: consta de una plataforma con capacidad de carga de dos sensores de observación terrestre, el primero de ellos denominado *Operational Land Imager* (OLI) y el *Thermal Infrared Sensor* (TIRS). OLI y TIRS recogen los datos de forma conjunta para proporcionar imágenes coincidentes de la superficie. Además, continúa la misma secuencia de trayectoria (también conocida como paths o rutas de acceso) como sus antecesores Landsat 4, Landsat 5 y Landsat 7. Esto permite que todos los datos sean referenciados al mismo sistema de coordenadas, continuando con el registro de datos desde hace décadas. El satélite almacena los datos del sensor OLI y TIRS en una grabadora de estado sólido incluida a bordo y transmite los datos a estaciones receptoras terrestres.
- El sistema terrestre: el cual proporciona la capacidad necesaria para la planificación y programación de las operaciones del Landsat 8 y todas aquellas necesarias para administrar y distribuir los datos.

Las imágenes Landsat 8 obtenidas por los sensores (OLI) y (TIRS) constan de nueve bandas espectrales con una resolución espacial de 30 m para las bandas de 1 a 7 y 9. Una banda nueva (1) (azul-profundo) es útil para estudios costeros y aerosoles y, otra nueva banda (9), que se emplea para la detección de cirrus. La resolución de la banda 8 (pancromática) es de 15 m. Las bandas térmicas, 10 y 11, son útiles para proporcionar temperaturas más precisas de la superficie y se toman con 100 m de resolución (Tabla 3.3). El tamaño aproximado de la escena es de 170 km de norte a sur por 183 km de este a oeste [64].

Tabla 3.3: Sensores y características de bandas de Landsat 8. Imagen extraída de USGS, 2013.

Sensores	Bandas	Longitud de onda	Resolución Espacial
OLI (Operational Land Imager)	1 - Costero / Aerosol	433 - 453 nm	30 m
	2 - Azul	450 - 515 nm	30 m
	3 - Verde	525 - 600 nm	30 m
	4 - Roja	630 - 680 nm	30 m
	5 - Infrarrojo cercano	845 - 885 nm	30 m
	6 - Infrarrojo de onda corta	1.560 - 1.660 nm	30 m
	7 - Infrarrojo de onda corta	2.100 - 2.300 nm	30 m
	8 - Pancromática	500 - 680 nm	15 m
	9 - Cirrus	1.360 - 1.390 nm	30 m
TIRS (Thermal Infrared Sensor)	10 - Infrarrojo termal o de onda larga	10.300 - 11.300 nm	100 m
	11 - Infrarrojo termal o de onda larga	11.500 - 12.500 nm	100 m

A continuación se describen las principales características de los productos proporcionados por el USGS [64]:

- Productos de Nivel 0 (L0): Los productos del tipo L0 son imágenes digitales con todas las transmisiones de datos y objetos sin formato. Estos productos están al mismo tiempo ordenados de manera proporcional, espacial y secuencialmente por bandas multiespectrales.
- Productos de Nivel 1 Radiometric (L1R): Los productos del tipo L1R consisten en datos de imágenes radiométricamente corregidas. Estos se encuentran derivados de datos L0 y son escalados a valores de radiancia espectral o reflectancia.
- Productos de Nivel 1 Sistemático (L1G): Los productos del tipo L1G consisten en productos de datos del tipo L1R con correcciones geométricas sistemáticas aplicadas y muestreos para el registro en una proyección cartográfica, estos datos se encuentran referenciados al Sistema Geodésico Mundial de 1984 (WGS84), G873, o a su versión actual.
- Productos de Nivel 1 Gt (L1Gt): Los productos del tipo L1Gt consisten en datos del tipo L1R con correcciones geométricas sistemáticas aplicadas y muestreos para el registro a una proyección cartográfica referenciada a WGS84, G873, o a su versión actual. Este tipo de datos (L1Gt) utilizan la información de posición a bordo o efemérides definitivas, así como el uso de los datos controlados de elevación para corregir los errores de paralaje.
- Productos de Nivel 1 Terrain (L1T): Los productos de datos L1T consisten en productos de datos L1R con correcciones geométricas sistemáticas aplicadas, utilizando para ello puntos de control terrestre (GCP) o información de posición integrada a bordo para entregar una imagen registrada a una proyección cartográfica, referenciada a WGS84, G873, o a su versión actual. Adicionalmente, los datos también contienen una corrección topográfica por el desplazamiento del terreno debido al relieve.

Las imágenes Landsat 8 fueron descargadas de la página oficial del USGS *, según disponibilidad para el área y periodo de estudio, de 30 m de resolución, multiespectrales y con un nivel de procesamiento L1T. En la Tabla 3.4, se muestran los datos de las mismas:

*Desde octubre de 2008, todas las imágenes de archivo y nuevas adquisiciones pueden solicitarse o descargarse gratuitamente desde USGS *Global Visualization View* (Glovis), la USGS Earthexplorer o USGS Landsat.

Tabla 3.4: Fechas y características de imágenes Landsat 8 utilizadas en el presente estudio.

Fecha	Número imagen
28/12/2013	LC82290822013362 LGN00
13/01/2014	LC82290822014013LGN00
19/04/2014	LC82290822014109LGN00

3.2. Imágenes SAR

El Radar es un sistema de sensoramiento remoto activo, que emite su propia energía en el intervalo de frecuencias de microondas y recibe los ecos de la señal reflejada por los objetos observados desde plataformas aéreas o satelitales. La principal diferencia de los sistemas de radar frente a los sistemas ópticos y pasivos, es la capacidad de obtener imágenes sin necesidad de energía solar; así mismo, opera independiente de las condiciones atmosféricas, ofrece mayor información sobre la textura del terreno y cuenta con la posibilidad de obtener información sobre los sustratos inferiores de las coberturas boscosas [12].

El desarrollo de los sistemas de radar ha sido impulsado por la misma necesidad de obtener datos espaciales en zonas de difícil acceso y de alta nubosidad. Las imágenes de radar proveen altos volúmenes de datos, ofrecen observación periódica y una amplia perspectiva de la superficie de la Tierra y sus recursos, además de permitir evidenciar los rasgos de las actividades humanas y su impacto. Es así como en la actualidad, para una determinada zona, se puede disponer de imágenes satelitales de radar cada 2 o 3 días, en modos de multi polarización con diferentes ángulos de observación y de alta resolución espacial.

Inicialmente, los radares eran de Apertura Real (*RAR, Real Aperture Radar*), que emitían en el rango del espectro de microondas y luego registraban las señales de retorno de los objetos terrestres con una resolución espacial limitada y controlada por la longitud física de la antena. Actualmente, los sistemas modernos de radar, utilizan las antenas de apertura sintéticas, que permiten mejorar la resolución espacial de la imagen mediante un sofisticado post procesamiento caracterizado por la simulación virtual del tamaño de la antena y la compresión de la señal utilizando los principios físicos del efecto Doppler [65].

Una imagen de radar es la relación de la energía de microondas emitida hacia la Tierra y la energía reflejada directamente de regreso al sensor. La energía que regresa al sensor se llama retrodispersión. La retrodispersión de un área de cobertura es dependiente de la topografía local, rugosidad en escala de centímetros y propiedades dieléctricas; estas últimas están directamente afectadas por los niveles de humedad. Los valores de retrodispersión bajos se representan como tonos de imagen oscuros o niveles de gris que se aproximan al negro, mientras que los valores de retrodispersión altos se muestran como tonos de imagen claros o niveles de gris aproximándose a blanco [66].

3.2.1. COSMO SkyMed

El sistema COSMO-SkyMed (*Constellation of Small Satellites for Mediterranean basin Observation*) fue planeado como una constelación de cuatro satélites de SAR para uso militar pero, también, con productos disponibles para usuarios civiles. Financiado por la Agencia Espacial Italiana y el Ministerio Italiano de Defensa, que iniciaron su trabajo en 1996 con un programa nacional de observación de la Tierra, lanzando el COSMO SkyMed 1 en junio del 2007 y y el COSMO SkyMed 4 en noviembre de 2010, proveyendo de información para un gran número de aplicaciones gracias a su cobertura global y en todas las condiciones meteorológicas, posibilidad de adquisición diurna y nocturna, alta resolución espacial y alta resolución temporal (frecuencia de revisita/respuesta), exactitud (geo-localización, radiometría, etc) y calidad de imágenes y su capacidad para interferometría [67].

De acuerdo al nivel de procesamiento (Figura 3.2), los productos COSMO SkyMed pueden adquirirse en cinco niveles diferentes [68]:

- Nivel 0, datos crudos (RAW): definido como datos crudos a bordo (después del descifrado y antes del desempaquetamiento) asociados con datos auxiliares incluyendo datos de calibración requeridos para producir productos de niveles mayores. Los datos son números complejos de fase y cuadratura (I y Q). En el contexto de SAR, un número complejo está representado por un par de números: el componente en fase real (I) y el componente de cuadratura imaginario (Q). Este nivel tiene el siguiente procesamiento en los datos originales, eliminación del protocolo de transmisión, descompresión de datos, estimación de estadísticas y formateo de datos.
- Nivel 1A, producto *Single-look Complex Slant* (SSC): definido como datos crudos enfocados en formato complejo, y en proyección slant range-azimuth (proyección de adquisición natural del sensor). El procesamiento aplicado en el nivel 0 es: Compensación de la ganancia del receptor, calibración interna, enfoque de datos, estimación de estadísticas de los datos de salida y formateo de datos de salida.
- Nivel 1B, producto *Detected Ground Multi-look* (DGM): obtenido mediante la detección, el multilooking y la proyección sobre una grilla regular de los datos Single-look Complex Slant. Este producto, consiste en datos enfocados SAR, ecualizados radiométricamente de manera interna, sin speckle, detección en amplitud. Se aplica al nivel 1A, el siguiente procesamiento: Reducción del ruido speckle mediante multilooking, detección de imagen (amplitud, que remueve la información de fase del archivo de datos), proyección elipsoide, evaluación de estadística y formateo de datos.
- Nivel 1C (GEC) y 1D (GTC), producto geocodificado: obtenido mediante la proyección del producto 1A sobre una grilla regular en un determinado sistema de referencia cartográfico. En el caso del nivel 1C la superficie es el elipsoide terrestre, mientras que en el nivel 1D un DEM es utilizado para aproximar la superficie terrestre real. El procesamiento llevado a cabo en el nivel 1B, es el procesamiento de GEC con el uso del DEM para la proyección.




Figura 3.2: Niveles de procesamiento de COSMO SkyMed. Imagen extraída de COSMO-SkyMed SAR Products Handbook.

Las imágenes de los COSMO SkyMed SAR se pueden obtener en distintos modos de adquisición, diversas polarizaciones, con distintas resoluciones especiales y tamaño de la escena, que son resumidos en la siguiente Tabla 3.5

Tabla 3.5: Características técnicas de imágenes SAR COSMO SkyMed. Imagen extraída de e-GEOS.

COSMO-SkyMed					
Bandas espectrales	3,1 cm - (Banda X)				
Modo	Un modo polarización - HH, VV, HV, o VH				Dos modos de polarización HH, VV, HV o VH
	Spotlight o Frame	HIMAGE o Stripmap	WideRegion o ScanSAR	Huge Region o ScanSAR	Ping Pong o Stripmap
Resolución espacial	1 m	3-15 m	30 m	100 m	15 m
Tamaño de escena	10 km x 10 km	40 km	100 km	200 km	30 km
Resolución radiométrica	8 bits/píxel				
Revisita	7 horas promedio				

En la Figura 3.3 se muestra la relación entre las resoluciones espaciales de los modos de adquisición



Figura 3.3: Resolución espacial de los modos de adquisición del sensor COSMO SkyMed. Imagen extraída de e-GEOS.

A los fines de este trabajo, se utilizaron imágenes SAR COSMO SkyMed del área de estudio, cedidas por la CONAE en el marco de la maestría, con una recurrencia de 15 días durante el período 2013-2014, en concordancia con salidas a campo realizadas en el marco del proyecto "Desarrollo, evaluación y aplicación de modelos para estimar variables agronómicas", aprobado y subsidiado por Secyt-UNC, que se lleva a cabo en la Facultad de Ciencias Agropecuarias. Estas, corresponden a imágenes Stripmap PingPong, con un nivel de procesamiento 1A, Single Look Complex, con configuración de polarización HH/VV y ángulo central de la escena mayor a 35°. En la Tabla 3.6, se muestran las características de las imágenes adquiridas:

Tabla 3.6: Fechas y características de imágenes COSMO SkyMed utilizadas en el presente estudio.

Fecha	Enfoque	Dirección de Orbita	Áng. Inc. Lejano	Áng. Inc. Cercano	Imagen
31/08/2013	Izquierda	Ascendente	48,84	47,02	CSKS2_SCS_B_PP_14_CO_LA_SF_20130831095929_20130831095936
01/10/2013	Izquierda	Ascendente	40,10	37,92	CSKS4_SCS_B_PP_09_CO_LA_SF_20131001100519_20131001100526
26/10/2013	Derecha	Ascendente	43,30	41,32	CSKS2_SCS_B_PP_11_CO_RA_SF_20131026104712_20131026104718
05/11/2013	Derecha	Descendente	43,30	41,31	CSKS2_SCS_B_PP_11_CO_RD_SF_20131105212439_20131105212447
22/11/2013	Derecha	Descendente	43,30	41,31	CSKS3_SCS_B_PP_11_CO_RD_SF_20131122212433_20131122212442
01/12/2013	Derecha	Ascendente	43,30	41,31	CSKS4_SCS_B_PP_11_CO_RA_SF_20131201104658_20131201104705
17/12/2013	Derecha	Ascendente	43,30	41,31	CSKS4_SCS_B_PP_11_CO_RA_SF_20131217104650_20131217104657
14/01/2014	Derecha	Ascendente	43,30	41,31	CSKS2_SCS_B_PP_11_CO_RA_SF_20140114104641_20140114104648
30/01/2014	Derecha	Ascendente	43,30	41,31	CSKS2_SCS_B_PP_11_CO_RA_SF_20140130104636_20140130104643
23/02/2014	Derecha	Descendente	22,24	18,86	CSKS1_SCS_B_PP_0A_CO_RD_SF_20140223213602_20140223213609
25/02/2014	Derecha	Descendente	43,30	41,32	CSKS2_SCS_B_PP_11_CO_RD_SF_20140225212402_20140225212410
23/03/2014	Derecha	Ascendente	43,30	41,32	CSKS4_SCS_B_PP_11_CO_RA_SF_20140323104620_20140323104627
06/04/2014	Derecha	Descendente	43,30	41,32	CSKS1_SCS_B_PP_11_CO_RD_SF_20140406212350_20140406212359
15/04/2014	Derecha	Descendente	41,73	39,60	CSKS2_SCS_B_PP_10_CO_RD_SF_20140414212351_20140414212359
22/04/2014	Derecha	Descendente	43,30	41,32	CSKS1_SCS_B_PP_11_CO_RD_SF_20140422212348_20140422212356
22/05/2014	Derecha	Ascendente	43,30	41,31	CSKS2_SCS_B_PP_11_CO_RA_SF_20140522104605_20140522104612
24/05/2014	Derecha	Descendente	43,30	41,31	CSKS1_SCS_B_PP_11_CO_RD_SF_20140524212339_20140524212347

En un futuro, con el fin de realizar un monitoreo y seguimiento de la evolución de catástrofes en tiempo casi real, la ASI *Agenzia Spaziale Italiana* y CONAE, pretenden mejorar la frecuencia de actualización de la información a menos de 12 horas. Para esto, se está desarrollando el SIASGE, Sistema Italo Argentino de Satélites para la Gestión de Emergencias, que estará integrado por los cuatro satélites, de la Constelación Italiana COSMO-SkyMed SAR, descriptos anteriormente, que operan en banda X (8GHz) y dos satélites SAOCOM SAR en banda L (1,3 GHz) provistos por la CONAE. Los seis, se encontrarán ubicados en órbitas polares a la misma altura, en distintos planos orbitales, de tal manera que el conjunto funcione como un instrumento con un enorme ancho de visión sobre la tierra [69].

3.3. Modelo Digital de Elevación del Terreno

En el pre-procesamiento de datos COSMO SkyMed se utilizó, para la corrección geométrica, el Modelo Digital de Elevación del Terreno (DEM) perteneciente al conjunto de datos topográficos tomados por la Misión Topográfica de Radar Shuttle (SRTM) de la NASA [70]. El SRTM de 90 m de resolución espacial, cubre el 80 % de la superficie terrestre entre, aproximadamente, los 60° de la latitud norte y los 56° de latitud sur. Estos datos fueron obtenidos mediante el empleo de dos radares de apertura sintética, uno en banda C (longitud de onda de 5,6 cm) el otro en banda X (longitud de onda de 3,1 cm). El primero, tuvo como objetivo generar cobertura de mapeo continua y el segundo, datos en franjas discretas de 50 km de ancho (cobertura casi continuas en las latitudes más altas), con errores de altitud dentro de un nivel de confianza del 90 %, mediante la interferometría con la diferencia entre las imágenes obtenidas [71].

3.4. Datos de campo

Los datos de campo fueron muestreados por los miembros del Proyecto de Investigación "Desarrollo, evaluación y aplicación de modelos para estimar variables astronómicas" (Proyecto aprobado por Secyt-UNC Res 123/13) que se desarrolla en la cátedra de Matemática de la Facultad de Agronomía de la Universidad Nacional de Córdoba.

La base de datos se construyó a partir de estos muestreos que fueron realizados en 65 lotes * durante viajes periódicos, aproximadamente cada 15 días, desde octubre de 2013 a abril de 2014. Las fechas (Tabla 3.7) de viajes, para la toma de datos de campo, se encontraron dentro de un intervalo de aproximadamente 7 días con respecto a las fechas de adquisición de imágenes COSMO, SPOT y Landsat.

Tabla 3.7: Fechas de muestreos en campo y de imágenes COSMO SkyMed, SPOT 5 y Landsat 8.

Salida a campo	Cosmo SkyMed	Spot 5	Landsat 8
04/09/2013	31/08/2013		
18/09/2013			
02/10/2013	01/10/2013		
09/10/2013			
25/10/2013	26/10/2013	18/10/2013	
06/11/2013	05/11/2013		
20/11/2013	23/11/2013		
03/12/2013	01/12/2013		
17/12/2013	17/12/2013		
30/12/2013		30/12/2013	28/12/2013
14/01/2014	14/01/2014		13/01/2014
30/01/2014	30/01/2014		
12/02/2014	23/02/2014		
27/02/2014	25/02/2014	01/03/2014	
13/03/2014		12/03/2014	
27/03/2014	23/03/2014	22/03/2014	
10/04/2014	06/04/2014		
	15/04/2014		
24/04/2014	22/04/2014		19/04/2014
06/05/2014	22/05/2014		
29/05/2014	24/05/2014		

En 10 de los lotes de maíz y soja, se relevaron en las fechas anteriores a la siembra datos de tipo de residuo que cubría el suelo y porcentaje de cobertura del mismo. Luego de la siembra, se incorporaron a las planillas datos sobre tipo de cultivo, altura de la planta, cantidad de plantas por metro lineal, distancia entre surcos de 52 cm, porcentaje de humedad gravimétrica del suelo a 5, 10 y 20 cm de profundidad (se promediaron todos los datos de muestreo) y estado fenológico del cultivo,

*De total de lotes, sólo en 10 de maíz y soja, se registraron las múltiples variables que se utilizaron en esta tesis. En el resto, solo se relevó tipo de cultivo para el testeo de las clasificaciones y el análisis estadístico general de sorgo, cuya proporción de área sembrada fue significativamente menor respecto de los otros cultivos.

según la escala desarrollada por Fehr y Caviness (1971) para soja [72] y la escala Ritchie y Hanway (1982) para maíz [73]. En la Tabla 3.8 se muestran los datos utilizados en esta tesis, correspondientes a una de las fechas que coincidió con la obtención de una imagen SPOT 5, mientras que las tablas con los datos completos y para todas las fechas cercanas a las fechas de las imágenes ópticas, pueden verse en el Anexo I.

Tabla 3.8: Datos de muestreos a campo para la zona en estudio para el 13 de marzo del 2014.

Lotes Relevados				13/03/2014			
Lotes	Rastrojo	Cultivo	Fecha de siembra	Estado Fenológico	Altura (cm)	Plantas x m	Humedad (%)
1	Soja	Maíz	14-18 de diciembre	R3-R4	263	3	25,31
2	Soja	Maíz	15 de diciembre	R4	254	3	23,26
3	Maíz	Soja	15 de noviembre	R6	87	14	22,07
4	Maíz	Soja	5-6 de noviembre	R6 - R7	97	23	21,18
5	Soja	Soja	5 de noviembre	R6 - R7	81	21	22,60
6	Soja	Soja	13 de noviembre	R6	81	12	23,90
7	Soja	Maíz	1-6 de diciembre	R4-R5	236	3.4	21,75
8	Soja	Soja	4-5 de noviembre	R6	81	11	20,66
9	Soja	Soja	5 de noviembre	R6	83	13	23,65
10	Soja	Maíz	2-4 de diciembre	R4-R5	260	3.2	26,06

Por otro lado, se obtuvieron datos de reflectancia de distintos rastrojos y cultivos de maíz y soja, medidos con espectroradiómetros a alturas entre 2,5 y 3,5 m en las zonas de Bell Ville y Monte Buey de la provincia de Córdoba. Estos datos fueron cedidos por la CONAE en el marco de la Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias, MAEARTE (Tabla 3.9)

Tabla 3.9: Datos de muestreo a campo para las zonas de Bell Ville y Monte Buey en lotes con rastrojos y cultivos de maíz y soja, para fechas de lectura con espectroradiómetro.

Fecha	Lugar	Rastrojo/Cultivo	Altura (cm)	Cobertura (%)	Estado Fenológico	NDVI
11/10/2012	Monte Buey	Rastrojo Maíz	30	70	Seca con tallos. Suelo húmedo.	0,071
11/10/2012	Monte Buey	Rastrojo Soja	20	40	Suelo húmedo oscuro.	0,018
12/12/2012	Bell Ville	Maíz	220	85	VT	0,855
25/03/2013	Monte Buey	Soja	50	60	R8	0,181
25/03/2013	Monte Buey	Maíz	250	80	R5	0,711

Métodos

3.5. Pre-procesamiento de imágenes

El pre-procesamiento de imágenes satelitales, se aplica como un paso inicial en la manipulación de imágenes, con el fin de corregir las distorsiones radiométricas y geométricas, así también, como para eliminar el ruido. Estas distorsiones radiométricas obedecen a mecanismos que alteran los valores de brillo de los píxeles y se deben fundamentalmente a interferencias atmosféricas y a efectos asociados a instrumentación, en las ópticas y al ruido speckle, asociado a la iluminación coherente de los satélites SAR [74].

3.5.1. SPOT 5 y Landsat 8

Las imágenes ópticas utilizadas en el estudio fueron calibradas a reflectancia al tope de la atmósfera (TOA) en primera instancia y luego a reflectancia a nivel de superficie con el software ENVI 4.8.

La señal recibida por los sensores se codifica en diferentes valores de Niveles Digitales (ND) de acuerdo a la reflexión de la radiación electromagnética de las cubiertas. El proceso inverso, conversión de los ND a reflectividades, se realiza en dos partes: la primera consiste en pasar los ND a valores de radiancia a partir de los valores de calibración y luego, estima los valores de reflectividad aparente, conociendo los valores de irradiancia solar y la fecha de adquisición de la imagen [75]. Este proceso de conversión a variables físicas de significado estándar permite comparar imágenes de un mismo sensor a lo largo del tiempo y de distintos sensores [12], de allí su importancia y necesidad.

El cálculo de la reflectividad aparente (en el tope de la atmósfera) se basa en la aplicando la siguiente fórmula [76]:

$$\rho TOA = \frac{\pi * L_{\lambda} * d^2}{E_{0,\lambda} * \cos\theta_s} \quad (3.1)$$

Siendo,

ρTOA = Reflectancia TOA.

π = Constante matemática aproximadamente igual a 3,14.

d = Distancia Tierra - Sol en el momento de la toma de la imagen, expresado en unidades astronómicas (ua).

L_{λ} = Radiancia espectral calculada anteriormente, en una banda espectral específica (en $W * m^{-2} * sr * nm^{-1}$).

$E_{0,\lambda}$ = Irradiancia espectral solar exoatmosférica, en una banda espectral determinada (en $W * m^{-2} * nm^{-1}$).

θ_s = Ángulo cenital solar en el momento de adquisición de la imagen (en radianes).

Los valores de reflectividad varían entre 0 y 1, correspondiendo el valor más bajo a superficies perfectamente absorbentes y el mayor a superficies perfectamente reflectoras, y depende no sólo de las condiciones físicas y químicas de las cubiertas, sino también de las condiciones de observación. Por otro lado, se asume que la observación se realiza para una atmósfera transparente, verticalmente, sobre suelo plano y superficies perfectamente lambertianas [77].

Los componentes de la atmósfera producen un efecto de absorción y dispersión que modifican la señal procedente de la cubierta, por lo que es necesario convertir la reflectividad TOA a reflectividad a nivel de la superficie terrestre. El algoritmo aplicado corrige la señal recibida por el sensor de la influencia y distorsiones radiométricas causadas por la atmósfera [78]. El método utilizado en este proceso, fue el propuesto por Chavez [79], conocido también como de sustracción del píxel oscuro, que toma en cuenta la transmisividad de la atmósfera en el camino Sol-Tierra y la dispersión atmosférica, asumiendo que existe una alta probabilidad de que existan píxeles negros dentro de la imagen.

$$\rho = \frac{\pi * [L_{\lambda} - L_{a,\lambda}] * d^2}{\cos\theta_s * E_0 * \tau_1 * \tau_2} \quad (3.2)$$

Siendo,

ρ = Reflectancia al nivel de superficie.

$E_{0,\lambda}$ = Radiancia exoatmosférica solar, en una banda espectral determinada (en $W * m^{-2} * nm^{-1}$).

τ_1 = Coeficiente de transmisión atmosférica en el camino Sol-Tierra.

τ_2 = Coeficiente de transmisión atmosférica en el camino Tierra-sensor.

$L_{a,\lambda}$ = Radiancia recibida por el sensor en un área donde sólo hay contribución de la atmósfera (área de sombra o agua según la región espectral) en $W * m^{-2} * nm^{-1}$.

L_λ = Radiancia del píxel a corregir.

θ_s = Ángulo cenital solar en el momento de adquisición de la imagen (radianes).

d = Distancia Tierra-Sol en unidades astronómicas (ua).

3.5.2. SAR COSMO SkyMed

Para el procesamiento de imágenes COSMO SkyMed se utilizó el software NEST 5.1, siguiendo los pasos descritos a continuación [80]:

1. Multilook: Este procesamiento combina varias imágenes incoherentemente como si se tratara de aspectos diferentes de una misma escena con el fin de reducir el aspecto moteado producido por el ruido speckle. Como resultado del proceso aplicado, la imagen multilooked mejora la interpretabilidad de la imagen. Además, el procesamiento de MultiLook es utilizado para llevar al píxel de la imagen a un tamaño nominal, comparando la resolución en *ground range* y en *acimut*. En este trabajo no se aplicó multilooking, sólo se llevó las imágenes a un píxel cuadrado con 1 look.
2. Calibración: El objetivo de la calibración SAR es el de proporcionar imágenes en las que los valores de los píxeles estén directamente relacionados con la retrodispersión de la escena. Las imágenes SAR, sin el proceso de calibración pueden utilizarse a fines de descripción cualitativa, sin embargo, este procedimiento es esencial cuando se requiere un uso cuantitativo de los datos y, en particular, cuando los productos corresponden a un nivel de procesamiento 1A. También, es necesario para la comparación de imágenes SAR de diferentes sensores de diferentes momentos, modos o procesadas por distintos procesadores.
3. Filtro Speckle: Este ruido se origina debido a que cada celda de la matriz asociada a un blanco extendido, contiene muchos centros retrodispersores cuyos ecos individuales, por interferencia constructiva o destructiva, originan píxeles oscuros o brillantes. Para su reducción se aplican filtros específicos que buscan conservar el valor de la media de la imagen y reducir su desvío estándar. Con el fin de reducir este ruido en las imágenes obtenidas, se aplicó un filtro Lee [81] con una ventana de 3*3 píxeles.
4. Corrección del terreno: En estas imágenes, las distancias pueden ser distorsionadas debido a las variaciones topográficas y la inclinación del sensor, principalmente en aquellos datos que provienen de lugares no directamente en el nadir del mismo. Las correcciones del terreno compensan estas distorsiones con el objetivo de lograr que la imagen sea lo más cercana a la realidad.

3.5.3. Co-registro de imágenes

En estudios multi-temporales o multi-sensor se requiere que las imágenes sean registradas cada una con respecto a la otra con el fin de que la geometría de las mismas coincida perfectamente. El procedimiento se llevó a cabo automáticamente con el software Nest versión 5.1 que permitió co-registrar una o más imágenes esclavas a partir de una maestra, con superposición total o parcial de las mismas. La precisión alcanzable en imágenes con la misma geometría de adquisición y tomadas en áreas planas, es de 0,2 píxeles [80]. Este procesamiento consiste en tres etapas:

1. Imágenes de entrada: Las imágenes de entrada pueden ser complejas o reales pero todas deben pertenecer al mismo tipo y deben tener el mismo sistema de proyección.
2. Stack: se crea un stack formado por la imagen principal y todas las esclavas. Los datos de las imágenes esclavas se re-muestran a la matriz geográfica de la imagen principal, de esta manera, comparten la misma información de geoposicionamiento, la misma dimensión y tamaño de píxel.
3. Puntos de control de terreno: se crea una alineación entre las imágenes maestra y esclavas, haciendo coincidir los puntos de control de terreno de la primera con los puntos de control de terreno del resto de las imágenes.

La imagen que se utilizó como maestra para el co-registro de todas las consideradas en este estudio, fue la correspondiente al sensor SPOT 5 de fecha 01 de marzo de 2014. Luego de una serie de pruebas, se concluyó que, para el área de estudio, la combinación de parámetros que mejor se ajusta al objetivo del presente trabajo es la que se describe en la Tabla 3.10:

Tabla 3.10: Parámetros para el co-registro de imágenes ópticas y radar.

Tipo de remuestreo	Convolución Cúbica
Número de Puntos de Control de Terreno	200
Ancho de la ventana de registro	64
Largo de la ventana de registro	64
Factor de interpolación Fila	2
Factor de interpolación Columna	2
Máximo de iteraciones	2
Tolerancia de los puntos de control de terreno	0,5
Umbral RMS	1
Método de interpolación	Interpolación Bilineal

Las medias y desvíos estándares para el co-registro de imágenes COSMO SkyMed, SPOT 5 y Landsat 8 fueron, respectivamente, los que se muestran en la Tabla 3.11

Tabla 3.11: Medias y desvíos estándares de los valores cuadráticos medios (RMS) del co-registro de imágenes de los satélites COSMO SkyMed, SPOT 5 y Landsat 8.

	Media RMS	Desvío Estándar RMS
Cosmo SkyMed	0,2045	0,2667
Spot 5	0,4702	0,2588
Landsat 8	0,2305	0,1662

3.6. Análisis exploratorio de los datos

3.6.1. Selección de regiones de interés

Para este trabajo, se seleccionaron regiones de interés (ROIs) (Figura 3.4) en cada una de las imágenes ópticas según los lotes muestreados a campo en el área de estudio (65 lotes) *, eligiendo entre 1500 y 2500 píxeles por cada uno y descartando los que corresponden al borde del lote para disminuir el error debido a la variabilidad en el estado de los cultivos entre las zonas internas del lote y los bordes del mismo. De igual manera, se consideraron para el análisis de imágenes SAR, ROIs de los 65 lotes pero con un tamaño de 100 píxeles aproximadamente. El propósito de disminuir la cantidad de píxeles fue el de intentar homogeneizar aún más la muestra para la clasificación en este tipo de imágenes.




Figura 3.4: ROIs de lotes muestreados a campo superpuestos en una imagen satelital SPOT 5, utilizados para el entrenamiento de los clasificadores aplicados.

*El roi correspondiente al Lote 7b fue renombrado a Lote 16.

Los bordes de los lotes están expuestos a condiciones diferentes que las de su interior y, por consiguiente, ocurre en ellos un crecimiento diferenciado de la vegetación y malezas. La Figura 3.5 muestra claramente como la vegetación del borde del lote 9 poseía un estado totalmente diverso al del interior del mismo lote.



Figura 3.5: Fotografías correspondientes al borde del Lote 9.

La elección de un área de interés se basa en la necesidad de ahorro de tiempo computacional y simplificación de los datos para su análisis [77]. Con este objetivo, los ROIs fueron empleados en el proceso de clasificación, la validez de la misma, el análisis exploratorio de datos y el de la vegetación.

3.6.2. Estadística descriptiva y test de hipótesis de la distribución de datos

El conocimiento de la estructura de los datos, es fundamental en el estudio y aplicaciones de imágenes satelitales, ya que permite decidir las operaciones de procesamiento, análisis y clasificación digital de las mismas [14]. Con este fin, se calcularon las medidas estadísticas que permiten describir las bandas de los tres sensores y se realizaron los test estadísticos para distribución normal y gamma, utilizando el paquete estadístico *R* [82].

Para la estadística descriptiva se calcularon las medias, desvíos estándar, mínimos, máximos, medianas, valores de asimetría y kurtosis para cada lote en cada una de las imágenes adquiridas para este estudio. Estas medidas, permiten identificar los valores mas representativos de los datos, de acuerdo a su concentración y evaluar su distribución [83]. Asimismo, se realizó para cada lote, un análisis de valores extremos con el fin de confirmar que la elección de las regiones de interés no incluían zonas sin cultivos o con cultivo en en estadios fenológicos muy diferentes. Para representar y resumir variables de tipo numérico, se construyeron gráficos box-plot.

A fin de conocer la distribución de los datos provenientes de las imágenes, se aplicaron test estadísticos. Para las ópticas, de las cuales se espera una distribución normal, se hizo uso del test de Kolmogorov-Smirnov. De la misma forma, basados en la teoría [84], [85], se realizó para las imágenes radar, Shapiro-Wilk para comprobar la no normalidad de estos datos y el test de Kolmogorov-Smirnov para verificar la distribución gamma de los mismos.

3.7. Análisis de la vegetación

3.7.1. Firmas espectrales

La firma espectral permite identificación del estado de la vegetación, además, la misma se aplica a la caracterización y diferenciación de cultivos. La reflectancia espectral característica de las plantas es determinada por las composición química y las propiedades físicas de las mismas. Esta reflectancia está directamente relacionada con la absorción de los pigmentos como la clorofila, los carotenos y el agua, entre otros, e influenciada por la estructura de la planta y las superficies, por este motivo, para hablar de una firma espectral típica de un cultivo determinado, se deben tener en cuenta las condiciones bajo las que se adquieren estas medidas [77].

La variabilidad de la respuesta espectral de la vegetación dependerá del área observada por el sensor, por ende, de la altura de observación del mismo; del ángulo de elevación solar (respuesta de la vegetación mayor con ángulos más bajos); de la geometría de la vegetación; de la longitud de onda y de las condiciones atmosféricas. Todos estos factores confieren un alto grado de complejidad a las medida espectral de las superficies cultivadas pero, también, gracias a esta complejidad, se pueden detectar cambios debido a efectos meteorológicos adversos, ataques de plagas, cambios en el uso de suelo, etc. [86].

Las firmas espectrales se obtuvieron, con el software ENVI 4.8, de los lotes en estudio para cada banda de la imagen SPOT correspondiente a las mismas fechas, rastros y cultivos de los datos de radiómetro y se contrastaron entre sí.

3.7.2. Índice de Vegetación de Diferencia Normalizada

La signatura espectral característica de la vegetación sana, muestra un fuerte contraste entre la baja reflectividad en el visible, especialmente en la banda roja (600 nm - 700 nm), alta reflectividad en el infrarrojo cercano (700 nm - 1100 nm) y baja, con presencia de algunos máximos relativos, a medida que se incrementa la longitud de onda. Mientras que en el visible los pigmentos de la hoja absorben la mayor parte de la energía que reciben, en el IRC, las paredes de las células de las hojas, que se encuentran llenas de agua, reflejan la mayor cantidad de energía. Esta diferencia es tanto mayor cuanto mayor es la densidad de la vegetación y mejor su estado fitosanitario (Figura 3.6). Por el contrario, cuando la vegetación sufre algún tipo de estrés, por presencia de plagas o por sequía, la cantidad de agua disminuye en las paredes celulares y por ende su reflectividad en el IRC, aumentando paralelamente en las longitudes del rojo, al tener menor absorción de clorofila. Esta diferencia en la respuesta espectral permite separar con relativa facilidad la vegetación sana de otras cubiertas [10].




Figura 3.6: Firma espectral de la vegetación sana. Imagen extraída de Chuvieco, 1996.

En base a la respuesta de reflectividad de la vegetación, se construyeron los Índices de Vegetación, de los cuales el más conocido y ampliamente aceptable como excelente indicador, es el Índice Normalizado de Vegetación o NDVI (3.3), introducido por Rouse (1974). No obstante las limitaciones en su uso radican en el efecto distorsionador del suelo y su saturación en valores altos de área foliar:

$$NDVI = \frac{(IRC - Rojo)}{(IRC + Rojo)} \quad (3.3)$$

Éste índice toma valores en el rango de -1 a +1, donde valores negativos indican superficies sin vegetación, tal como agua, nieve o nubes y valores positivos indican presencia de vegetación, donde valores mayores indican incremento de la misma en un rango entre 0,2 y 0,8 [87]. El comportamiento de los índices de vegetación en un píxel a lo largo de una serie de imágenes mensuales permite, además, observar los cambios estacionales de la vegetación y obtener su firma fenológica que permita la clasificación de los cultivos [6]. El uso de este tipo de índices puede ser útil para medir abundancia y cobertura de la vegetación a nivel de lote para estimar superficie sembrada e identificar y cuantificar zonas de distintas potencialidades de rendimiento, así también como conocer el uso de suelo agrícola a nivel de lote.

En este trabajo, se analizó el comportamiento de la vegetación para las diferentes longitudes de ondas en el rango de los sensores Landsat 8 y SPOT 5, a través del NDVI, con el fin de observar el estado de la vegetación en los lotes relevados y la diferencias entre los cultivos.

3.8. Identificación y clasificación de coberturas

Históricamente, se han empleado y estudiado diversos métodos de clasificación supervisada y no supervisada ([22], [23], [25], [26], entre otros). En general, las redes neuronales artificiales han mostrado una capacidad clasificadora superior a otras técnicas, con la ventaja de poderse utilizar independientemente del cumplimiento de supuestos teóricos relativos a distribuciones estadísticas o paramétricas [88], por este motivo, el método es aplicable a imágenes radar. Sin embargo, en este tipo de imágenes, el reconocimiento de cultivos resulta dificultoso y, en general, no es posible obtener buenos resultados.

El desarrollo de las técnicas de clasificación de imágenes SAR ha habido avances significativos con el fin de extraer información sobre cobertura de la tierra. Este progreso es evidente en los enfoques de la descomposición polarimétrico y modelos estadísticos. Prestigiosos estudiosos apelan a metodologías de reconocimiento y diferenciación de cultivos basada en distancias estocásticas, motivo por el cuál se creyó pertinente analizar, también, la diferenciación entre cultivos de soja y maíz a partir de estas técnicas.

3.8.1. Relación entre datos ópticos y radar

En la región agrícola argentina, la distribución de las lluvias permite el uso del suelo durante todo el año. Sin embargo, la época del año de mayor humedad y nubosidad, coincide con la época de cultivos de verano, lo que dificulta muchas veces la obtención de imágenes satelitales en óptimas condiciones y con una resolución temporal suficiente para el seguimiento de los cultivos. Los radares trabajan a longitudes de onda en la que la cobertura nubosa es transparente, por lo que resultan datos útiles para aumentar la resolución espacial y temporal de estudios agrícolas, sin embargo son datos de difícil interpretación. Por otro lado, el índice de vegetación NDVI, fue uno de los más utilizados y estudiados en teledetección para estimar cantidad, calidad y desarrollo de la vegetación desde 1974. Encontrar una relación entre este dato de imágenes ópticas y parámetros de las imágenes radar nos permitiría complementar la información proveniente de ambos tipo de sensores.

En base a esto, se analizó la relación entre valores de reflectancia y NDVI de imágenes ópticas con valores de retrodispersión de la banda X de Cosmo SkyMed, así como la relación temporal de la diferencia de valores de NDVI con las distancias entre valores de retrodispersión. Se calcularon en R los coeficiente de correlación de Pearson que toman valores entre 1 y -1: un valor de 1 indica una relación lineal perfecta positiva y un valor de -1 indica una relación lineal perfecta negativa. El valor 0 (cero), indica relación lineal nula.

3.8.2. Redes neuronales

La teoría y modelado de redes neuronales artificiales está inspirada en la estructura y funcionamiento de los sistemas nerviosos y, por lo tanto, intentan reproducir el comportamiento del cerebro. Como éste, la RN realizan una simplificación, identificando los elementos relevantes del sistema sobre una cantidad de información excesiva o redundante [89]. Para empezar, una RN se define por su topología o arquitectura caracterizada por la organización y disposición de las neuronas en la red, formando capas o agrupaciones. La topología, junto con el número de las capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas, son fundamentales en la configuración de la red [28]. El sistema, puede considerarse como un grafo cuyos nodos tienen funcionamiento similar, los cuales propagan la información a través de las distintas conexiones.

De esta forma, cada *neurona o nodo*, I recibe una serie de *entradas*, I_1, I_2, \dots, I_n que es multiplicada por un *peso* asociado a su conexión, $w_1, w_2, \dots, w_{m,n}$. Luego, se suman estas entradas ponderadas y se les aplica una *función de activación*, f para generar la señal de salida de la neurona I , que es propagada a las neuronas de la capa siguiente O (capa oculta), progresivamente hasta la capa de *salida*, que suministra el valor S final (Figura 3.7) [27].




Figura 3.7: Estructura general de una red neuronal. Imagen basada en Bocco, 2007.

Las *funciones de activación* más comunes son [90]

- Función Logística

$$\text{logsig}(x) = \frac{1}{1 + \exp\{-x\}} \quad (3.4)$$

- Función Hiperbólica

$$\text{tansig}(x) = \frac{2}{1 + \exp\{-2x\}} - 1 \quad (3.5)$$

A su vez, el aprendizaje supervisado, se caracteriza porque el proceso se realiza mediante un entrenamiento controlado por un agente externo que determina la respuesta que debería general la red a partir de una entrada determinada. Se suelen considerar tres formas de llevarlo a cabo [91]:

1. Aprendizaje por corrección del error: Consiste en ajustar los pesos de las conexiones de la red en función del error cometido en la salida.
2. Aprendizaje por refuerzo: Se basa en no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada.
3. Aprendizaje estocástico: Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

Una vez diseñada la arquitectura de la red (capas y número de neuronas por capa) y las funciones que la regirán, se tiene que proceder a entrenar la red para que *aprenda* a dar la respuesta adecuada a la configuración de estímulos o patrones de entrada que se le presenten, estas se llama fase de entrenamiento. En la misma, la RN encuentra los pesos w que permiten obtener la respuesta más próxima a la deseada para todos los patrones que se le presentan. A continuación, debe realizarse una segunda fase, con patrones independientes de los anteriores para los cuales también se conocen las respuestas a fin de realizar el test o validación.

Fase de entrenamiento

El proceso de entrenamiento de las RN se inicia con la presentación de un conjunto de datos, de los cuales se conoce la respuesta deseada, y permiten a la misma, adaptar sus pesos sinápticos, para que la respuesta sea la correcta. Los pesos se calculan de forma iterativa minimizando el error entre la salida obtenida por la red neuronal y la salida deseada [92] hasta que los valores de los pesos permanecen estables. El final de esta etapa será cuando se alcance la cantidad de iteraciones o valores de errores menores a los pre-establecidos.

La corrección del error consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red, es decir, en función del error obtenido en la salida ajustados con el algoritmo conocido como de retropropagación [28].

$$\Delta w_{ij} = \alpha y_i (d_j - s_j) \quad (3.6)$$

Siendo,

Δw_{ij} = Variación de la conexión entre la neuronas i y j ($\Delta w_{ij} = w_{ijactual} - w_{ijanterior}$).

s_i = Valor de salida de la neurona i.

d_j = Valor de salida deseado para la neurona j.

s_j = Valor de salida obtenido en la neurona j.

α = Factor de aprendizaje ($0 < \alpha \leq 1$) que regula la velocidad del aprendizaje.

Fase de validación o prueba

Una vez que la red ha aprendido, es decir, ajustado los pesos en el proceso de aprendizaje, se comienza con la fase de validación [92]. El conjunto de datos que se utiliza para validar las clasificaciones, correspondieron a lotes independientes y en la misma proporción de aquellos utilizados para el entrenamiento de la red. Con los resultados de esta fase, se calcularon los estadísticos que permiten decidir la bondad y ajuste del modelo, matrices de confusión, exactitud global y los coeficientes kappa obtenidos en las clasificaciones.

3.8.2.1. Configuración de la red

En este estudio, la clasificación de imágenes satelitales, se realizó con la herramienta de clasificación supervisada con Redes Neuronales del software ENVI, versión 4.8. El algoritmo *Neural Net* de este software, emplea la regla de aprendizaje de retropropagación y permite especificar la función de activación (logística o hiperbólica), el umbral de entrenamiento (determina la contribución del peso interno con respecto al nivel de activación del nodo), factor de aprendizaje o tasa de entrenamiento (determina la magnitud del ajuste de los pesos), momento de entrenamiento (acelera el proceso de convergencia de los pesos, teniendo en cuenta la dirección del incremento tomada en la iteración anterior y permitiendo pequeños valores en el coeficiente de aprendizaje con un aprendizaje más rápido y menos oscilaciones), el Error Cuadrático Medio (RMS) de salida (es aquel error en el que el entrenamiento de la red debe detenerse), el número de capas ocultas y la cantidad de iteraciones.

Conjunto de entrenamiento

La clasificación supervisada se basa en la disponibilidad de datos de entrenamiento derivados del conocimiento previo que se tiene de los tipos de cobertura que conforman parte del área de estudio. A partir de esto, se define la característica espectral de cada clase teniendo en cuenta la variabilidad de las mismas en el espacio, se entrena la red y se la compara con la realidad con un conjunto de datos de validación.

Los conjuntos de entrenamiento y test, se seleccionaron basados en los ROIs definidos previamente, de los cuales se utilizaron la mitad para entrenar la red y la otra mitad para su testeó. Se conformaron seis clases para la clasificación de imágenes ópticas anteriores a la siembra, donde sólo interesaba observar la proporción de rastros de soja y maíz y siete clases para las imágenes de fechas donde el cultivo ya estaba en emergencia.

- Rastrojo
 - Maíz
 - Soja
- Cultivos
 - Maíz
 - Soja
 - Sorgo

Dado que las imágenes corresponden a una amplia zona del centro de Córdoba, abarcando más que superficie agrícola, se tuvieron en cuenta otras clases con el propósito de mejorar la clasificación al tener en cuenta las diferentes respuestas espectrales en la escena considerada.

- Suelo desnudo
- Agua
- Ciudad (centros urbanos, casas rurales, pavimento, etc.)
- Otros (en las imágenes anteriores a la siembra se refiere a cultivos de trigo y cualquier otro cultivo de invierno, cortinas de árboles, etc. y, en las imágenes posterior a la siembra, a pasturas, maní y alfalfa)

Datos de entrada a la red

Se clasificaron imágenes SPOT 5, Landsat 8 y COSMO SkyMed, recortadas en el área de interés, con un tamaño de 7.406.352 píxeles y utilizando los datos de reflectancia correspondientes a las cuatro bandas de SPOT 5, seis bandas de Landsat 8 (azul, verde, rojo, infrarrojo cercano y las dos bandas de infrarrojo de onda corta) y ambas polarizaciones de COSMO SkyMed.

Arquitectura de la red

La red empelada es un Perceptrón Multicapa que emplea un algoritmo de aprendizaje de retropropagación del error, es decir, adapta sus pesos para adquirir un entrenamiento a partir de un conjunto de pares de patrones de entrada-salida. La red está compuesta por una capa de entrada, una capa de salida y capas intermedias sin conexión con el exterior, llamadas capas ocultas.

En la clasificación de imágenes satelitales, el número de nodos de entrada viene establecido por la cantidad de bandas de cada satélite utilizado. A su vez, los nodos de salida están determinados por el número de clases definidas para cada imagen. En la elección del número de capas ocultas se optó por utilizar sólo una, cantidad propuesta por defecto en el software ENVI 4.8.

Configuración paramétrica en ENVI

Con el objetivo de presentar las RN que permitieran la mejor clasificación, se compararon diversas configuraciones paramétricas para varias fechas de imágenes SPOT 5 (ya que tienen la mejor resolución espacial), con parámetros preestablecidos en el software (Tabla 3.12). Se encontraron dos configuraciones que arrojaron valores de coeficientes Kappa aceptables. Una vez comprobadas (entrenadas y validadas), las distintas redes neuronales que se consideraron, se seleccionó la configuración para la clasificación de todas las imágenes ópticas. En cuanto al RMS de entrenamiento, ninguna de las corridas alcanzó una salida con el valor del error especificado (0,1), sino que éstos estuvieron entre 0,25 y 0,46 píxeles.

Tabla 3.12: Configuraciones de prueba para clasificación con el algoritmo de redes neuronales de ENVI para la imagen SPOT 5 del 12 de marzo.

Nº de Prueba	1	2	3	4	5	6	7	8	9
Función de Activación	Logística								
Umbral de Entrenamiento	0,9	0,9	0,9	0,7	0,7	0,7	0,3	0,1	0,1
Tasa de Entrenamiento	0,2	0,2	0,2	0,2	0,2	0,02	0,2	0,2	0,1
Momento de Entrenamiento	0,9	0,7	0,3	0,9	0,7	0,9	0,9	0,9	0,9
RMS de Salida	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
Capas Ocultas	1	1	1	1	1	1	1	1	1
Nº de Iteraciones	1000	1000	1000	1000	200	200	200	200	200
Precisión (%)	71,9	70,7	71,16	71,9	72,5	75,2	72,5	72,2	75,2
Coefficiente Kappa	0,63	0,62	0,62	0,63	0,64	0,66	0,64	0,64	0,66

Evaluación de los resultados

Para la selección de la mejor combinación, primero y la validación de las clasificaciones luego, se tuvieron en cuenta los resultados de la matriz de confusión. Esta matriz es una herramienta de evaluación que compara los resultados obtenidos en la clasificación con la realidad, permitiendo obtener diversas medidas de interés respecto a la precisión. Entre los estadísticos comúnmente utilizados, la exactitud global o precisión (razón entre el número total de píxeles correctamente clasificados por el número total de píxeles de referencia, en porcentaje) y el coeficiente kappa (medida de concordancia entre los valores predichos y observados, nos dice cuán bien clasificados están los píxeles,; k=0,21-0,4, débil; k=0,41-0,60, moderada; k=0,61-0,80, buena y k=0,81-1,00, muy buena) [93]. Asimismo,

estas matrices muestran en su diagonal la proporción de píxeles bien clasificados correspondientes a cada clase, lo clasificados por omisión (píxeles que debieran ser de una clase pero se clasificaron como otra) o comisión (píxeles que se incluyen erroneamente en una determinada clase) y sus totales.

Clasificación temporal de imágenes radar

La misma metodología, se aplicó a la clasificación temporal de las imágenes radar. Se probaron diversas combinaciones de parámetros y fechas (desde enero a mayo) y se resolvió utilizar la misma configuración que en las ópticas pero aumentando el número de iteraciones a 1000. Se utilizaron todos los lotes relevados y sólo aquellas imágenes que abarcaron toda la zona de estudio. En este caso, la capa de entrada se conformó por 12 bandas de 6 imágenes radar y la de salida por las siete clases definidas para aquellas imágenes posteriores a la siembra.

3.8.3. Distancias estocásticas

El SAR, al moverse a lo largo de su trayectoria, ilumina hacia un lado de la dirección de vuelo, franjas continuas y paralelas entre sí de la superficie en estudio y acumula la información de las microondas que se reflejan. El blanco permanece en el haz de la antena durante unos instantes y es observado por el radar desde numerosos puntos a lo largo de la trayectoria del satélite, lo que es equivalente a prolongar la longitud real de la antena [94]. La distancia entre el radar y el objetivo en la superficie, en la dirección perpendicular al vuelo, se llama alcance y se conoce como acimut a la distancia a lo largo de la trayectoria. Mediante un procesamiento digital de la señal, la imagen puede enfocarse y, obtenerse así, una resolución mejor que la de un radar convencional. La resolución acimutal mejora considerablemente al considerarse el efecto Doppler que tiene lugar como consecuencia del desplazamiento del satélite [95]. Al ser, los objetos reflectores, superficies irregulares, los rayos emitidos por el radar regresan al sensor habiendo recorrido distintas distancias y habiendo acumulado así diferencias de fase. Dependiendo del valor de esta diferencia, los rayos interferirán constructiva, parcial o destructivamente. En una zona homogénea dará como resultado un efecto ficticio de moteado. Este fenómeno de interferencia a gran escala, es conocido como *Speckle* [96].

Los datos de SAR pueden ser ajustados mediante varias distribuciones (Gamma, Rayleigh, Raíz de Gamma, Exponencial y distribuciones K) dependiendo, entre otros factores, del grado de homogeneidad de las áreas en estudio [97]. En este sentido, la imagen puede ser entendida como un conjunto de regiones, en la que los píxeles cerrados son observaciones de variables al azar, que siguen una determinada distribución. Por lo tanto, medidas de disimilitud estocásticas se pueden utilizar como herramienta de procesamiento de imágenes para evaluar diferencias entre distribuciones que describen diferentes áreas [98].

En la mayoría de los datos provenientes de imágenes SAR, el ruido speckle no es gaussiano, ni aditivo y limita la capacidad para interpretar este tipo de imágenes (distinción entre bordes, clasificación de blancos, reconocimiento, segmentación e inversión de parámetros biofísicos) [99]. Por éste motivo muchos autores [85], [100], [101], [99] proponen distribuciones estadísticas que modelen los datos de forma adecuada. Uno de los modelos más utilizados es el Modelo Mutiplicativo, que supone que el valor observado en cada coordenada de la imagen es el resultado de observar la variable aleatoria Z que está compuesto por el producto XY , donde X modela el backscatter del terreno e Y el ruido speckle [84]. El modelo de speckle es tomado como un caso especial de un modelo multiplicativo con RCS (radar cross section: σ) constante. El modelo estadístico para el backscatter dependerá de varios parámetros que están relacionados a la rugosidad y la textura del objeto [102].

Torres et al. [100] modelaron la heterogeneidad mediante una distribución Gamma. La distribución de los datos de multilook en intensidad, en regiones homogéneas, está dada por el producto de la constante $X \sim \lambda$ y una variable aleatoria gamma $Y \sim \Gamma(L, L)$, y se denota $Z \sim \Gamma(L, \frac{L}{\lambda})$ con densidad $f_z(z; L, \lambda) = \frac{L^L}{\lambda^2 \Gamma(L)} Z^{L-1} \exp(-\frac{Lz}{\lambda})$, donde Γ es la función Gamma, $z, \lambda > 0$ y $L > 0$ es el número equivalente de looks.

Los estimadores de Máxima Verosimilitud basados en muestras Z_1, \dots, Z_n , de variables aleatorias independientes, idénticamente distribuidas son la media de la muestra $\hat{\lambda} = n^{-1} \sum_{i=1}^n Z_i$ y la solución de la ecuación no lineal $\ln \hat{L} - \psi^0(\hat{L}) - \ln n^{-1} \sum_{i=1}^n Z_i + n^{-1} \sum_{i=1}^n Z_i \ln Z_i = 0$, donde ψ^0 es la función digamma. Las distancias estocásticas permiten comparar dos distribuciones de probabilidad, siendo Z_1 y Z_2 dos variables aleatorias definidas sobre el mismo espacio de probabilidad, cuyas funciones de densidad son $f_{Z_1}(z; \theta_1)$ y $f_{Z_2}(z; \theta_2)$. La distancia utilizada en este trabajo fue la Distancia de Hellinger, debido a su menor costo computacional, en términos de cantidad de operaciones [100]. Se define de la siguiente manera [103]:

$$\Delta d_h(Z_1, Z_2) = 1 - \frac{2^L (\lambda_1 \lambda_i)^{\frac{L}{2}}}{(\lambda_1 + \lambda_i)^L} \quad (3.7)$$

Este método es un estadístico razonable para evaluar si dos muestras de datos provienen de la misma distribución. Las distancias son más pequeñas cuando se aplica a muestras de rugosidad similares, y más grande en caso contrario [98]. Pueden ser convenientemente dimensionadas para representar propiedades estadísticas, transformándose en test estadísticos [104].

Test de Hellinger

$$S_H = \frac{8mn}{m+n} \left(1 - \frac{2^{\hat{L}} (\hat{\lambda}_1 \hat{\lambda}_i)^{\frac{\hat{L}}{2}}}{(\hat{\lambda}_1 + \hat{\lambda}_i)^{\hat{L}}} \right) \quad (3.8)$$

De esta forma, con el uso de R se calculó y evaluó el comportamiento de las distancias entre muestra del mismo cultivo y de cultivos diferentes con el fin de explorar los datos para futuros trabajos.

Capítulo 4

Resultados

4.1. Pre-procesamiento de imágenes

4.1.1. SAR COSMO SkyMed

Las imágenes que resultaron del pre-procesamiento de datos SAR, se obtuvieron georeferenciadas y en valores de intensidad. En la Figura 4.1 se pueden ver los sucesivos nivel de procesamiento y los cambios en el tamaño del píxel y la disminución del ruido speckle característico de estos sensores.




Figura 4.1: Imágenes resultantes de aplicar una serie de herramientas de preprocesamiento para el tratamiento y formación de la imagen final SAR.

Los productos finales fueron imágenes de cada fecha en niveles de intensidad y georeferenciada, listas para su análisis (Figura 4.2).



Figura 4.2: Imagen SAR final, resultante del preprocesamiento, en valores de intensidad y georeferenciada.

4.2. Análisis de datos

4.2.1. Distribución de datos y estadística descriptiva

La presentación de los resultados del análisis estadístico del uso del suelo para el área de estudio se presenta en esta sección para tres lotes representativos del set de datos, cuyo resultado se mostrarán en las tablas y figuras correspondientes. Los mismos son, Lote 2, Lote 4 y Lote 16, que poseen los distintos tipos de rastrojos (sin cultivos) y cultivos (Tabla 4.1).

Tabla 4.1: Lotes con tipos de rastrojos y cultivos seleccionados como representativos en la zona de estudio.

Lote 2	Lote 4	Lote 16
Cultivo y Rastrojo	Cultivo y Rastrojo	Cultivo y Rastrojo
Rastrojo de soja	Rastrojo de maíz	Rastrojo de maní
Maíz	Soja	Sorgo

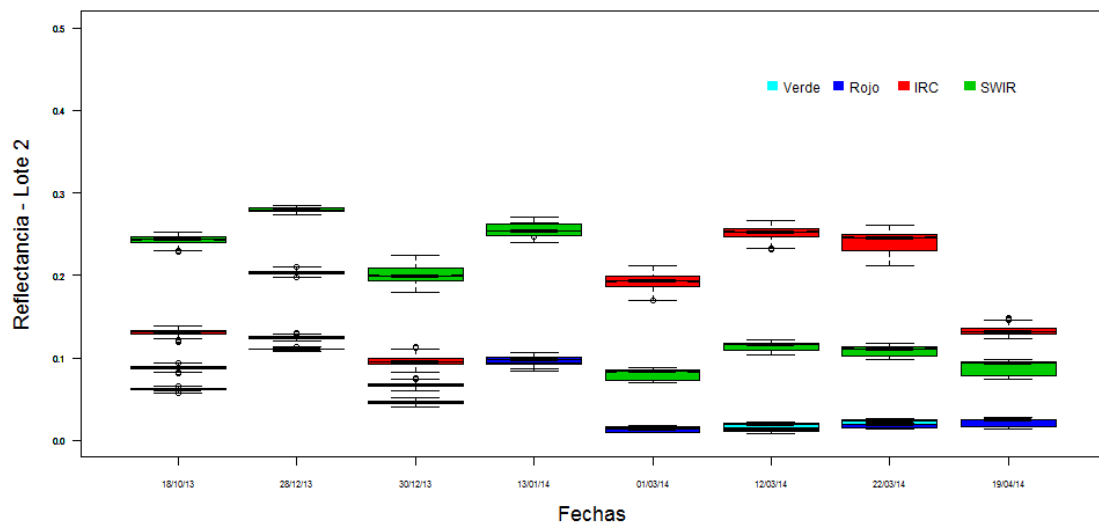
Estadística de imágenes ópticas

Para los datos provenientes de los satélites SPOT 5 y Landsat 8, se presentan en las Tablas 5.2 (Anexo II), los resúmenes estadísticos de todas las bandas para cada imagen. En general, pudo observarse, que los valores de las medias y las medianas variaron de forma mínima o nula entre ellos y, los coeficientes de asimetría y kurtosis, en casi todos los casos resultaron muy cercanos a cero, lo que se traduce en datos distribuidos de forma simétrica y con tendencia a la normalidad [105]. En varias bandas, si bien las medias y las medianas fueron similares, los valores de los coeficientes de

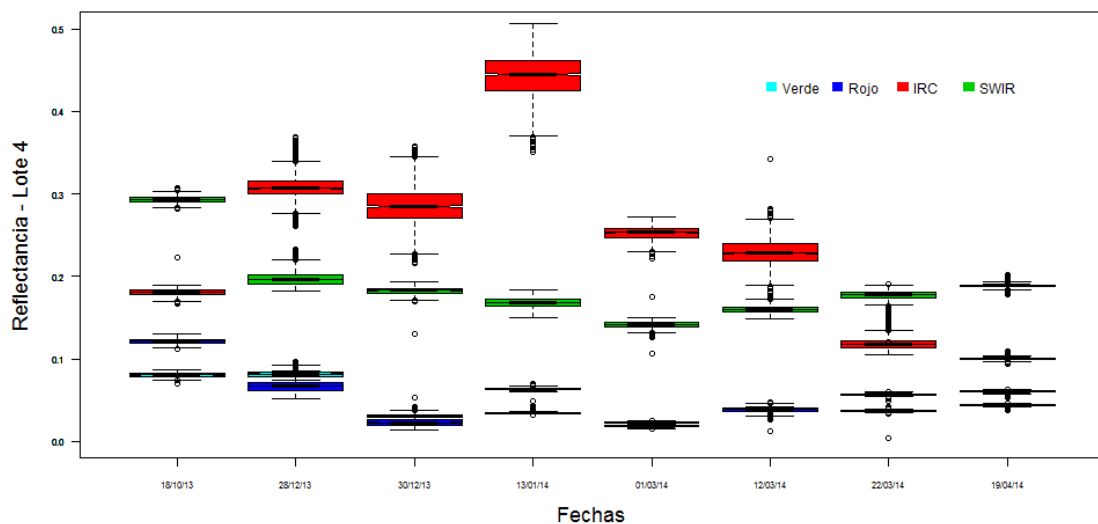
asimetría y kurtosis superaron el intervalo comprendido entre $\pm 0,5$, por lo cual, según este criterio, no se considera una curva normal.

Las medidas estadísticas dentro de un lote, tanto en valores físicos de reflectancia como en índices de vegetación, son útiles para diferenciar situaciones de manejo dentro de un lote; determinar estados de la vegetación, ya sea por eventos adversos o manejo, dentro y entre lotes del mismo cultivo, así también como para la detección de otro tipo de anomalías e información que sirva al productor o tomador de decisiones.


Con el fin de mostrar gráficamente los valores de reflectancia observados en las imágenes, se realizaron los gráficos box-plot para cada lote seleccionado comparando cada una de las fecha de los sensores ópticos (Figura 4.3).



(a) Lote 2 con rastrojo de soja y cultivo maíz.



(b) Lote 4 con rastrojo de maíz y cultivo de soja.



(c) Lote 16 con rastrojo de maní y cultivo de sorgo.

Figura 4.3: Box-plot de reflectancias de lotes seleccionados para distintas fechas y tipos de rastrojos y cultivos en imágenes SPOT 5 y Landsat 8.

Las figuras anteriores muestran la evolución temporal de los valores de reflectancia en cada uno de los cultivos y para cada banda en las regiones del espectro correspondientes al verde (banda 1), rojo (banda 2), infrarrojo cercano (banda 3) e infrarrojo de onda corta (banda 4). Visualmente, en todos los lotes, las bandas 3 y 4 arrojaron las mayores diferencias entre los cultivos.

Los lotes sólo con rastrojos de soja y maíz, relevados a campo, tuvieron un comportamiento espectral similar en ambos casos, de acuerdo con sus valores de reflectancia. En el caso particular de los lotes seleccionados, se encontraron valores levemente mayores para el rastrojo soja, pero en el conjunto de datos las variaciones espectrales no son suficientes para diferenciar entre ambos, utilizando datos de satelitales ópticos en esta época (anterior a la siembra).

Entre los meses de noviembre y diciembre comenzó la siembra de cultivos de grano grueso, por lo tanto, en estas fechas la reflectancia de la superficie fue influenciada por el suelo desnudo o rastrojo precedente y el cultivo en sus primeras etapas fenológicas. En todas las fechas existió diferencias entre los cultivos a partir de los valores de reflectancia.

En los lotes con maíz, en las fechas de diciembre, se observaron valores más elevados para la banda en el infrarrojo de onda corta que en el cercano, coincidentemente con lo que se espera en cultivos con coberturas y densidades de vegetación bajas. Esto se corresponde con el estadio de este cultivo (entre V2 y V4, Tabla 5.1, Anexo I), sembrado en este mes. A partir de enero, los valores de reflectancia en la banda 3 comienzan a ser más elevados con el aumento de la cobertura.

En el caso de la soja, que se sembró alrededor de un mes antes que el maíz, los valores en las primeras fechas hasta mediados de marzo, se correspondieron con los de la vegetación con una mayor densidad y/o mayor cobertura, con bajos niveles en el visible, un aumento en el infrarrojo cercano y, luego, una disminución (en menor proporción que valores en el rango visible) en el infrarrojo de onda corta. Contrariamente, en marzo se registraron rangos en el infrarrojo cercano menores a los de infrarrojo de onda corta, debido a que el cultivo estaba en estado de madurez y/o senescencia (R7-R8) a finales de marzo y, fue cosechado en el mes de abril.

El sorgo mostró, en todas las fechas analizadas, valores mayores en la banda 3 que en la banda 4 exceptuando la imagen de octubre ya que, al igual que los otros, fue sembrado después de esta fecha.


En resumen, en la soja se encontraron valores de reflectancia mayores que en el maíz y, en particular, en este cultivo la banda 3 tuvo valores por encima de la banda 4 desde la siembra hasta la madurez del mismo. Mientras que en el maíz, los mismos fueron mayores para la banda 4 que para la banda 3, en los primeros estadios y, menores en estadios más avanzados. Por otro lado, en el sorgo la reflectancia fue siempre mayor en el infrarrojo cercano. Estas diferencias en los valores de reflectancia de los distintos y en distintas fechas indican que es posible reconocer una separabilidad de los cultivos y reconocer su estado.

Los lotes sólo con rastrojos de soja y maíz, relevados a campo, tuvieron un comportamiento espectral similar en ambos casos, de acuerdo con sus valores de reflectancia. En el caso particular de los lotes seleccionados, se encontraron valores levemente mayores para el rastrojo soja, pero en el conjunto de datos las variaciones espectrales no son suficientes para diferenciar entre ambos, utilizando datos de satelitales ópticos en esta época (anterior a la siembra).

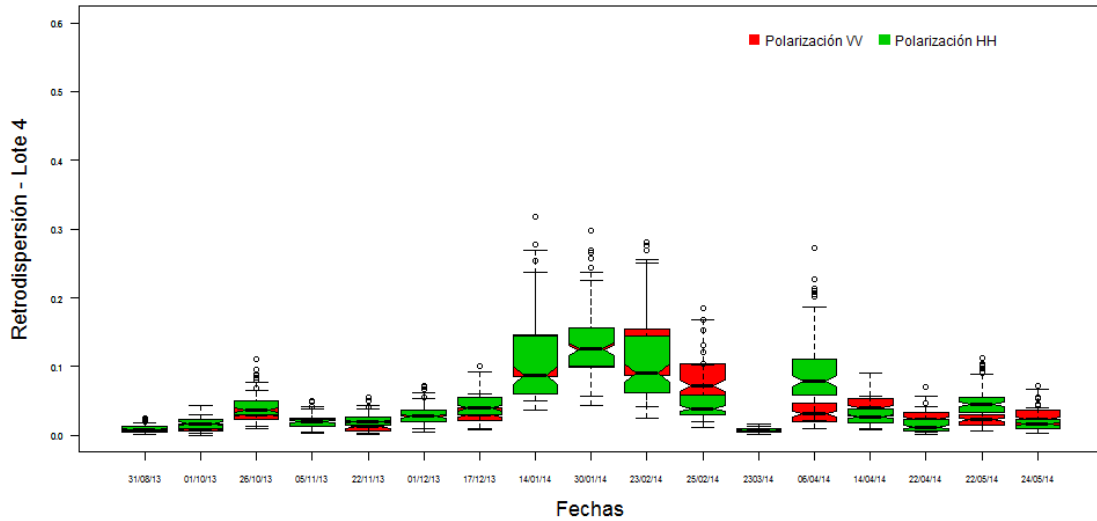
Estadística de imágenes radar

Con el fin de comparar datos ópticos y de radar, se realizó el análisis estadístico descriptivo de los datos SAR. En la Tabla 5.3 (Anexo II) se muestran los valores estadísticos resumen de los mismos lotes representativos que se evaluaron para imágenes ópticas. Los valores de asimetría y kurtosis se alejaron en todos los casos de 0 y siempre fueron mayores a la media, lo que nos indicó que la curva tiene una sola cola y su comportamiento no se corresponde con una distribución normal en ninguna de las polarizaciones.


Los datos provenientes de radar se representan gráficamente con box-plot (Figura 4.4), al igual que los datos ópticos, de ambas polarizaciones para cada lote representativo del set de datos.



(a) Lote 2 con rastrojo de soja y cultivo maíz.



(b) Lote 4 con rastrojo de maíz y cultivo de soja.



(c) Lote 16 con rastrojo de maní y cultivo de sorgo.

Figura 4.4: Box-plot de lotes seleccionados para distintas fechas y tipos de rastrojos y cultivos en imágenes COSMO SkyMed.

De forma general, en los gráficos de las imágenes de SAR se observó que los valores de retrodispersión, medidos en intensidad, fueron mayores en la época de mayor cobertura de la vegetación y que, estos valores, en soja y maíz son menores a 0,2. Asimismo, la polarización VV tuvo valores más elevados para soja que para el resto de los cultivos, en el mismo periodo.

En determinadas fechas, las imágenes no contemplan la totalidad del área de estudio dejando determinados lotes fuera de la escena, con la inevitable consecuencia de la falta de datos en dichos casos (en el gráfico del lote 2 se ven cuatro fechas con datos incompletos).

Test de hipótesis de la distribución de datos ópticos y radar

Luego del análisis de los datos ópticos (analítico y gráfico), se ajustaron los mismos a una distribución normal, obteniendo los parámetros de media y desvío estándar característicos de cada muestra. Con estos, se determinó la función de densidad normal teórica y se compararon, mediante el test de Kolmogorov- Smirnov (KS), las densidades observadas (Tabla 4.2).

Tabla 4.2: Resultados de test de normalidad de Kolmogorov-Smirnov (estadístico D y p-valor) para las imágenes (a) SPOT 5 y (b) Landsat 8.

(a) Test de normalidad para imágenes SPOT 5

Imágenes Spot 5	Banda	Lote 2			Lote 4			Lote 16		
		D	p-valor	Normalidad	D	p-valor	Normalidad	D	p-valor	Normalidad
1810/2013	B1	0,09	1,00	No Rechaza	0,13	1,00	No Rechaza	0,15	1,00	No Rechaza
	B2	0,13	1,00	No Rechaza	0,18	0,99	No Rechaza	0,18	1,00	No Rechaza
	B3	0,17	1,00	No Rechaza	0,08	1,00	No Rechaza	0,15	1,00	No Rechaza
	B4	0,15	1,00	No Rechaza	0,25	0,98	No Rechaza	0,19	0,95	No Rechaza
3012/2013	B1	0,17	1,00	No Rechaza	0,12	1,00	No Rechaza	0,17	1,00	No Rechaza
	B2	0,12	1,00	No Rechaza	0,13	1,00	No Rechaza	0,17	1,00	No Rechaza
	B3	0,12	1,00	No Rechaza	0,47	0,05	No Rechaza	1,00	0,00	Rechaza
	B4	0,20	0,99	No Rechaza	0,59	0,01	Rechaza	1,00	0,00	Rechaza
0103/2014	B1	0,58	0,00	Rechaza	0,20	0,99	No Rechaza	0,38	0,21	No Rechaza
	B2	0,50	0,04	Rechaza	0,29	0,45	No Rechaza	0,29	0,62	No Rechaza
	B3	0,90	0,00	Rechaza	0,17	1,00	No Rechaza	1,00	0,00	Rechaza
	B4	0,40	0,42	No Rechaza	0,23	0,90	No Rechaza	0,64	0,01	Rechaza
1203/2014	B1	0,41	0,11	No Rechaza	0,27	0,66	No Rechaza	0,12	1,00	No Rechaza
	B2	0,36	0,31	No Rechaza	0,25	0,96	No Rechaza	0,24	0,73	No Rechaza
	B3	0,11	1,00	No Rechaza	0,29	0,45	No Rechaza	1,00	0,00	Rechaza
	B4	0,22	0,78	No Rechaza	0,13	1,00	No Rechaza	0,11	1,00	No Rechaza
2203/2014	B1	0,55	0,08	No Rechaza	0,20	0,99	No Rechaza	0,20	0,99	No Rechaza
	B2	0,60	0,01	Rechaza	0,20	0,99	No Rechaza	0,21	0,90	No Rechaza
	B3	0,91	0,00	Rechaza	0,38	0,29	No Rechaza	0,92	0,00	Rechaza
	B4	0,45	0,21	No Rechaza	0,06	1,00	No Rechaza	0,25	0,87	No Rechaza

(b) Test de normalidad para imágenes Landsat 8

Imágenes Landsat 8	Bandas	Lote 3			Lote 4			Lote 16		
		D	p-Valor	Normalidad	D	p-Valor	Normalidad	D	p-Valor	Normalidad
28/12/2014	B1	0.11	1.00	Acepta	0.21	0.92	Acepta	0.36	0.46	Acepta
	B2	0.12	1.00	Acepta	0.22	0.99	Acepta	0.33	0.38	Acepta
	B3	0.18	1.00	Acepta	0.25	0.87	Acepta	0.27	0.81	Acepta
	B4	0.10	1.00	Acepta	0.20	0.99	Acepta	0.33	0.73	Acepta
	B5	1.00	0.00	Rechaza	0.18	1.00	Acepta	0.20	0.99	Acepta
	B6	0.18	0.99	Acepta	0.27	0.83	Acepta	0.30	0.79	Acepta
13/01/2014	B1	0.13	1.00	Acepta	0.42	0.25	Acepta	0.23	0.88	Acepta
	B2	0.20	0.99	Acepta	0.40	0.18	Acepta	0.13	1.00	Acepta
	B3	0.13	1.00	Acepta	0.18	1.00	Acepta	0.44	0.09	Rechaza
	B4	0.17	1.00	Acepta	0.30	0.76	Acepta	0.17	0.97	Acepta
	B5	0.11	1.00	Acepta	0.13	1.00	Acepta	0.14	1.00	Acepta
	B6	0.19	0.94	Acepta	0.12	1.00	Acepta	0.14	1.00	Acepta
19/04/2014	B1	0.13	1.00	Acepta	0.42	0.25	Acepta	0.23	0.88	Acepta
	B2	0.20	0.99	Acepta	0.40	0.18	Acepta	0.13	1.00	Acepta
	B3	0.13	1.00	Acepta	0.18	1.00	Acepta	0.44	0.09	Rechaza
	B4	0.17	1.00	Acepta	0.30	0.76	Acepta	0.17	0.97	Acepta
	B5	0.11	1.00	Acepta	0.13	1.00	Acepta	0.14	1.00	Acepta
	B6	0.19	0.94	Acepta	0.12	1.00	Acepta	0.14	1.00	Acepta

Como muestra la Tabla 4.2, para el satélite SPOT 5 (a), en unas pocas fechas y bandas (alrededor de 10) se observaron valores de p menores a 0,05 por lo cual se rechazó la hipótesis nula (H_0) de normalidad de los datos. Del mismo modo, en el caso del satélite Landsat 8, se observa en la Tabla 4.2 (b) que el estadístico arrojó valores de p mayores a 0.05 en la gran mayoría de las bandas, por lo que no se rechazó la H_0 . Se destaca que para el cultivo de soja, en las imágenes del primer sensor, sólo se rechazó la normalidad en un único caso y, en ninguno caso, en Landsat.

En el análisis de distribución de datos de radar, en cada polarización, se rechazó en la mayoría de los casos la hipótesis nula de normalidad de los datos aplicando un test de Shapiro-Wilk (Anexo II, Figura 5.5). Se realizó el ajuste a la distribución gamma, de la misma forma que para los datos ópticos, comparando mediante el test de KS las densidades gammas teóricas con las observadas (Tabla 4.3). En todos los casos y, para ambas polarizaciones, se consideró que no existen evidencias suficientes para el rechazo de la H_0 que postula la distribución de probabilidad gamma de estos datos.

Tabla 4.3: Resultados de test de distribución Gamma de Kolmogorov-Smirnov (estadístico D y p-valor) para imágenes COSMO SkyMed.

Imágenes Cosmo SkyMed	Banda	Lote 2			Lote 4			Lote 16		
		D	p-valor	Gamma	D	p-valor	Gamma	D	p-valor	Gamma
31/08/2013	VV	0,16	0,98	No Rechaza	0,13	1,00	No Rechaza	0,23	0,90	No Rechaza
	HH	0,19	0,94	No Rechaza	0,13	1,00	No Rechaza	0,18	1,00	No Rechaza
01/10/2013	VV	0,13	1,00	No Rechaza	0,17	1,00	No Rechaza	0,27	0,83	No Rechaza
	HH	0,20	0,99	No Rechaza	0,18	0,95	No Rechaza	0,27	0,83	No Rechaza
26/10/2013	VV	0,08	1,00	No Rechaza	0,27	0,83	No Rechaza	0,14	1,00	No Rechaza
	HH	0,21	0,92	No Rechaza	0,14	1,00	No Rechaza	0,07	1,00	No Rechaza
05/11/2013	VV	0,10	1,00	No Rechaza	0,13	1,00	No Rechaza	0,38	0,21	No Rechaza
	HH	0,25	0,98	No Rechaza	0,30	0,79	No Rechaza	0,15	1,00	No Rechaza
22/11/2013	VV	0,22	0,99	No Rechaza	0,20	0,99	No Rechaza	0,21	0,90	No Rechaza
	HH	0,30	0,79	No Rechaza	0,30	0,79	No Rechaza	0,22	0,99	No Rechaza
01/12/2013	VV	0,20	0,99	No Rechaza	0,10	1,00	No Rechaza	0,20	0,94	No Rechaza
	HH	0,09	1,00	No Rechaza	0,19	0,94	No Rechaza	0,10	1,00	No Rechaza
17/12/2013	VV	0,17	1,00	No Rechaza	0,14	1,00	No Rechaza	0,09	1,00	No Rechaza
	HH	0,17	0,96	No Rechaza	0,30	0,79	No Rechaza	0,29	0,62	No Rechaza
14/01/2014	VV	0,17	0,96	No Rechaza	0,22	0,99	No Rechaza	0,18	0,95	No Rechaza
	HH	0,08	1,00	No Rechaza	0,30	0,76	No Rechaza	0,25	0,98	No Rechaza
30/01/2014	VV	0,17	1,00	No Rechaza	0,18	1,00	No Rechaza	0,22	0,99	No Rechaza
	HH	0,15	1,00	No Rechaza	0,20	0,95	No Rechaza	0,13	1,00	No Rechaza
23/02/2014	VV	0,09	1,00	No Rechaza	0,17	1,00	No Rechaza	0,23	0,88	No Rechaza
	HH	0,21	0,92	No Rechaza	0,11	1,00	No Rechaza	0,09	1,00	No Rechaza
25/02/2014	VV				0,07	1,00	No Rechaza	0,09	1,00	No Rechaza
	HH				0,10	1,00	No Rechaza	0,14	1,00	No Rechaza
23/03/2014	VV	0,28	0,49	No Rechaza	0,10	1,00	No Rechaza	0,67	0,01	Rechaza
	HH	0,13	1,00	No Rechaza	0,08	1,00	No Rechaza	0,33	0,52	No Rechaza
06/04/2014	VV	0,42	0,25	No Rechaza	0,20	0,99	No Rechaza	0,15	1,00	No Rechaza
	HH	0,57	0,02	Rechaza	0,13	1,00	No Rechaza	0,25	0,98	No Rechaza
14/04/2014	VV	0,25	0,98	No Rechaza	0,30	0,79	No Rechaza	0,25	0,98	No Rechaza
	HH	0,29	0,62	No Rechaza	0,25	0,85	No Rechaza	0,12	1,00	No Rechaza
22/04/2014	VV				0,21	0,92	No Rechaza	0,25	0,87	No Rechaza
	HH				0,18	1,00	No Rechaza	0,25	0,98	No Rechaza
22/05/2014	VV	0,33	0,54	No Rechaza	0,15	1,00	No Rechaza	0,15	1,00	No Rechaza
	HH	0,29	0,45	No Rechaza	0,21	0,90	No Rechaza	0,18	1,00	No Rechaza
24/05/2014	VV				0,12	1,00	No Rechaza	0,09	1,00	No Rechaza
	HH				0,11	1,00	No Rechaza	0,25	0,87	No Rechaza

4.3. Análisis de la vegetación

4.3.1. Firmas espectrales

Con el fin de diferenciar espectralmente los lotes, se graficaron las reflectancias en función de la longitud de onda, obteniendo así la firma espectral para tres fechas: una del lote sólo con rastrojo, otra del mismo con rastrojo y cultivo recién implantado y, la última, con el cultivo en un estadio fenológico mas avanzado. Se utilizaron firmas espectrales obtenidas a campo, de la librería de CONAE, para verificar que los cultivos en esta zona y sobre las imágenes utilizadas en este trabajo, siguen un patrón espectral semejante.

En la Figura 4.5, se representa el comportamiento espectral de los distintos tipos de rastrojos para los lotes en estudio, para la imagen SPOT 5 correspondiente al 18 de octubre de 2013 y se compararan con las firmas espectrales correspondientes tomadas en la localidad de Monte Buey, Córdoba.




Figura 4.5: Firmas espectrales de rastrojos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 18 de octubre de 2013.

Pudo comprobarse que en ambos casos, los valores de reflectancia tuvieron la misma tendencia en las distintas longitudes de onda, tanto entre aquellos extraídos de la imagen como los tomados con espectroradiómetro. En el caso del maíz, los datos de radiómetro en Monte Buey fueron menores que los datos obtenidos en el área de estudio, mientras que, para la soja los valores adquiridos con este instrumento resultaron mayores que aquellos obtenidos mediante sensado remoto, lo que puede deberse a diferentes niveles de cobertura de suelo, a la posición del rastrojo o la altura. Sin embargo, esto no se pudo comprobar debido a que no se tienen éstos datos para el análisis pertinente. De todas maneras, y lo que es positivo para la evaluación en este estudio, el comportamiento de las curvas resultó similar en las distintas longitudes de onda evaluadas.

En el mes de diciembre, la tendencia de las firmas espectrales fue creciente para los tres lotes de maíz (Figura 4.6), si bien en los lotes 1 y 2, el crecimiento, fue diferente que en el lote 7. En los primeros, su comportamiento se asemejó al de rastrojo pero el lote 7 mostró una firma espectral diferente debido, probablemente, a un estadio más avanzado ya que fueron sembrados con una semana de diferencia aproximadamente (ver Tabla 3.8). No se obtuvo firma de la imagen del lote 10 para esta fecha, ya que el mismo cayó fuera del área de cobertura de la imagen adquirida. Lo mismo ocurrió con la firma espectral de radiómetro para la soja. Aunque puede verse que, aquellas obtenidas del sensor, para los distintos lotes, resultaron similares entre si.

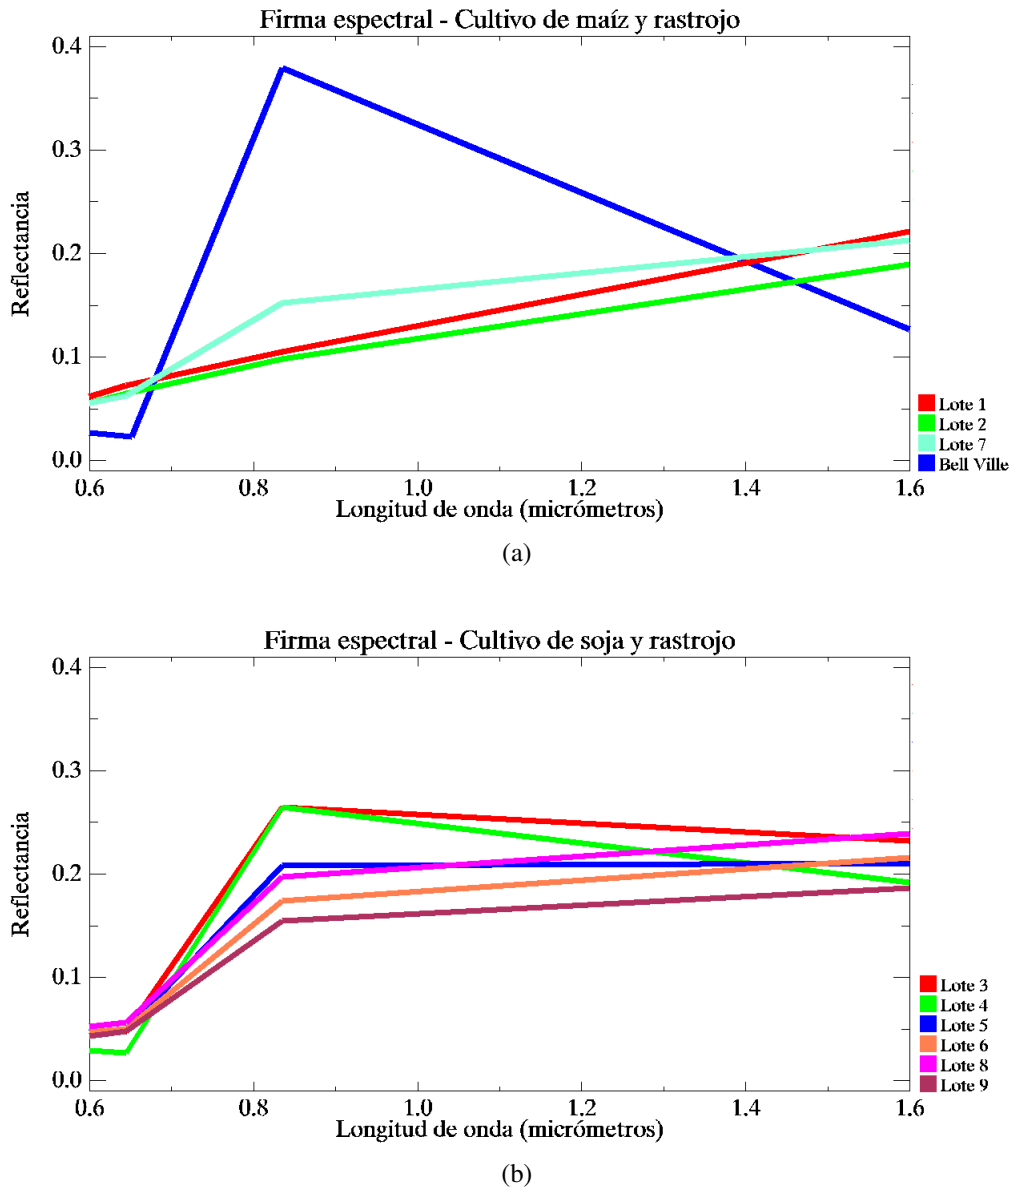


Figura 4.6: Firmas espectrales para rastrojos con cultivos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 30 de diciembre de 2013.

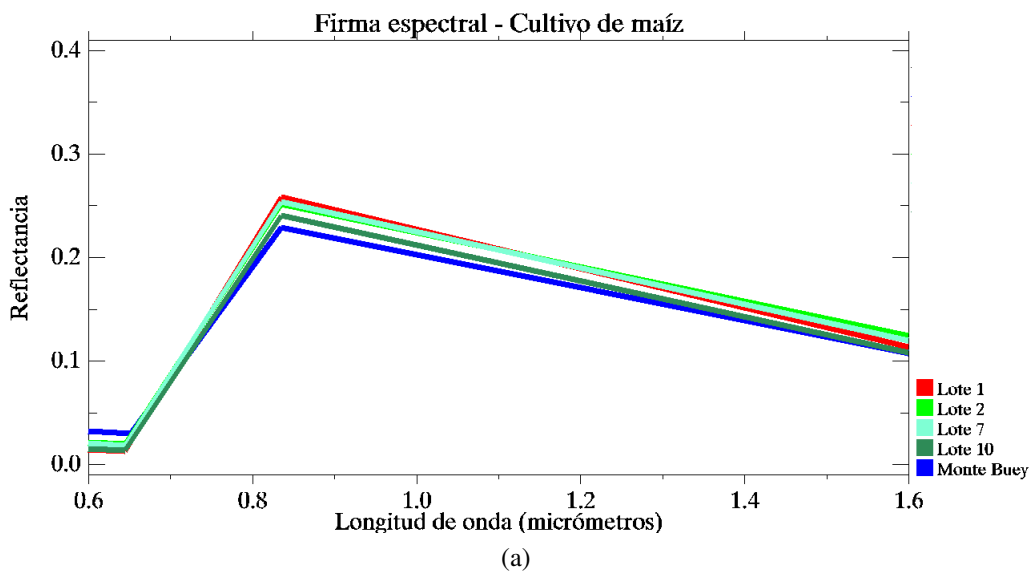
La firma tomada con radiómetro en la zona de Bell Ville para esta fecha, presenta diferencias de aquellas que se observan para el área de estudio. Estas, podrían deberse a la discrepancia en las fechas de siembra, el grado de cobertura del suelo y el rastrojo precedente a la siembra, ya que mientras menos avanzado sea el estadio de la vegetación mayor será la influencia del suelo desnudo

y/o rastrojo en la respuesta espectral obtenida. Si bien muchos de estos datos no se obtuvieron, la altura de la planta, el estadio fonológico del cultivo y su NDVI (Tabla 4.4) mostraron que el maíz en la zona de Bell Ville se encontraba en una etapa de crecimiento más avanzada y su cobertura era mayor que en el área de estudio para la misma época y, considerando que, en esta región es habitual la modificación de la fecha de siembra de ese grano, se puede pensar que este dato se obtuvo de un maíz temprano, mientras que, en el área de estudio el maíz analizado fue un tardío debido a su fecha de siembra.

Tabla 4.4: Datos de campo de muestreo y NDVI del mes de diciembre en la zona de Bell Ville y en el área de estudio para lotes con cultivo de maíz.

	Bell Ville	Lote 1	Lote 2	Lote 7
Fecha de muestro	12/12/2012	17/12/2013	17/12/2013	17/12/2013
Altura (cm)	220	9	9	34
Estadio	VT	V2	V2	V7
NDVI	0,85	0,16	0,17	0,44

Las firmas espectrales de la Figura 4.7 para ambos cultivos, tienen comportamientos similares a la respuesta registrada con radiómetro para la misma fecha en la localidad de Monte Buey (ver Tabla 4.5). En el caso del maíz, todos los lotes se encuentran iniciando la madurez. Mientras que la soja, presenta este estado en los lotes 3,6, 8 y 9 (si bien se muestra en la tabla estadios diferentes en los lotes 6 y 8, hay que considerar que los datos de campo fueron tomados 5 días después que las imágenes. Asimismo, los valores de NDVI muestran esta diferencia) y, el resto, ya están en plena madurez. Los lotes 3 y 6 fueron sembrados en fecha posteriores al resto, el lote 9 fue afectado por un evento de granizo y resembrado pero del lote 8 no se tuvo conocimiento de un episodio similar y no se pudo identificar la causa de la diferencia.



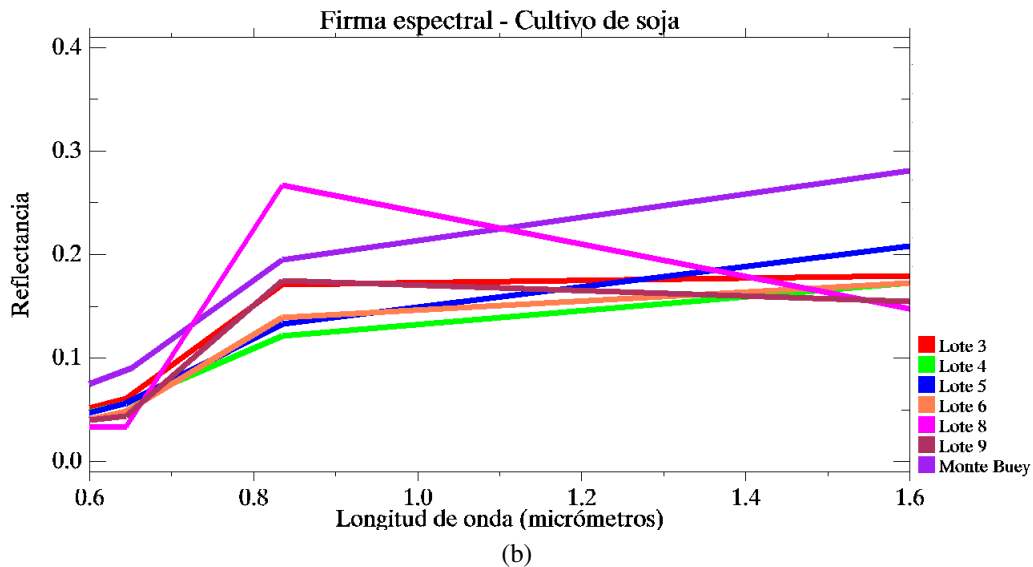


Figura 4.7: Firmas espectrales para cultivos de maíz (a) y soja (b) en todos los lotes de la imagen SPOT 5 del 22 de marzo de 2014.

Tabla 4.5: Datos de campo de muestreo y NDVI del mes de marzo en la zona de Monte Buey y en el área de estudio, para lotes con cultivo de (a) maíz y (b) soja.

(a) Cultivo de maíz

	Monte Buey	Lote 1	Lote 2	Lote 7	Lote 10
Fecha muestreo	25/03/2013	28/03/2014	28/03/2014	28/03/2014	28/03/2014
Altura (cm)	250	256	256	232	267
Estadio	R5	R4	R4	R4-R5	R4-R5
NDVI	0,71	0,89	0,86	0,86	0,88

(b) Cultivo de soja

	Monte Buey	Lote 3	Lote 4	Lote 5	Lote 6	Lote 8	Lote 9
Fecha muestreo	25/03/2013	28/03/2014	28/03/2014	28/03/2014	28/03/2014	28/03/2014	28/03/2014
Altura (cm)	50	79	93	73	78	68	73
Estadio	R8	R7	R8	R8	R8	R8	R7
NDVI	0,18	0,57	0,35	0,36	0,58	0,72	0,74

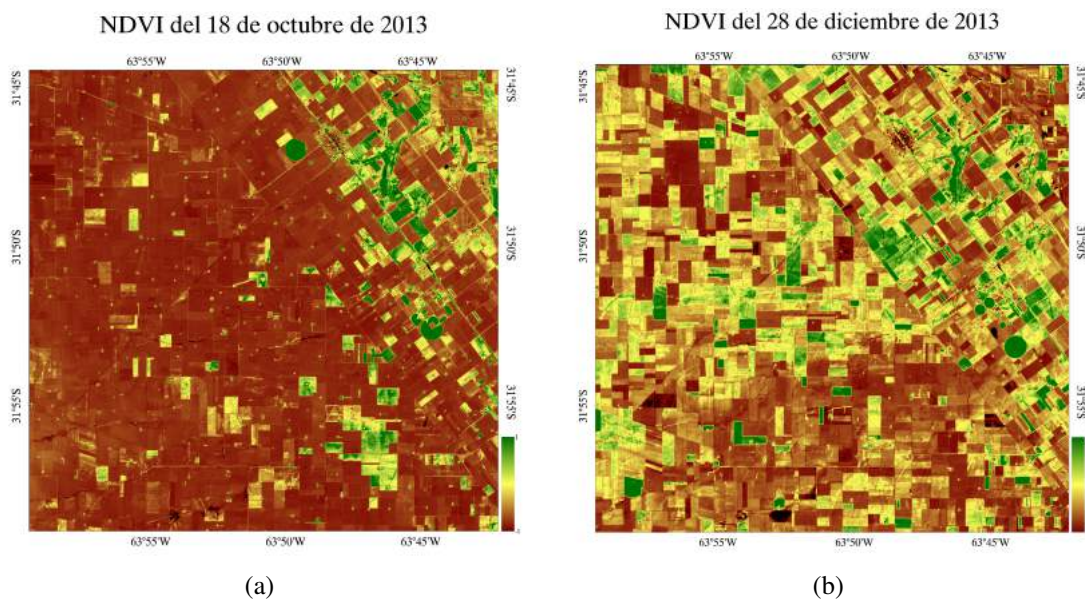
La caracterización espectral de los cultivos para su diferenciación, mediante el uso de imágenes satelitales de sensores multiespectrales e hiperespectrales, es una de las prácticas más comunes en teledetección. Numerosos estudios han demostrado que es posible la separabilidad entre cultivos, malezas y diversas especies vegetales [106], [107], [6], así también como la discriminación de parámetros críticos de estas especies y del suelo, tales como el estado fenológico, la estructura de la vegetación, el contenido de agua, entre otros [108]. Asimismo, existen una gran cantidad de bibliotecas espectrales de especies vegetales, algunas de las cuales son: librería MEDSPEC [109] creada en colaboración por 7 países Mediterráneos, la de Southampton en el Reino Unido [110], la de Kentucky en Estados Unidos [111] o, también, de clases geológicas como la biblioteca del USGS [62] o

la ASTER [112]. En el país, numerosas instituciones, como el INTA y la CONAE, cuentan con bases de datos espectrales útiles para la identificación de objetos remotamente.

El comportamiento espectral de los cultivos de maíz y soja en las imágenes utilizadas (con el procesamiento descrito implementado) tienen una tendencia similar en las regiones del espectro del visible e infrarrojo cercano y de onda corta, a aquellas obtenidas a campo con el instrumento de espectroradiómetro y, por ende, son representativas de dichos cultivos. Comparando entre cultivos, puede verse que los rastrojos de ambos no presentan diferencias espectrales entre ellos, mientras que en diciembre y marzo las firmas de soja se diferenciaron del maíz, principalmente, por las diferencias en sus estados fenológicos.

4.3.2. Índice de Vegetación de Diferencia Normalizada

Las imágenes de NDVI de los satélites SPOT 5 y Landsat 8, fueron clasificadas con el software ENVI, en una gama de colores que van de marrón (valores más bajos de NDVI) a verde (para los valores más altos). Esto nos permitió observar más claramente y, a simple vista, los cambios a través del tiempo en el área de interés, Figura 4.8.



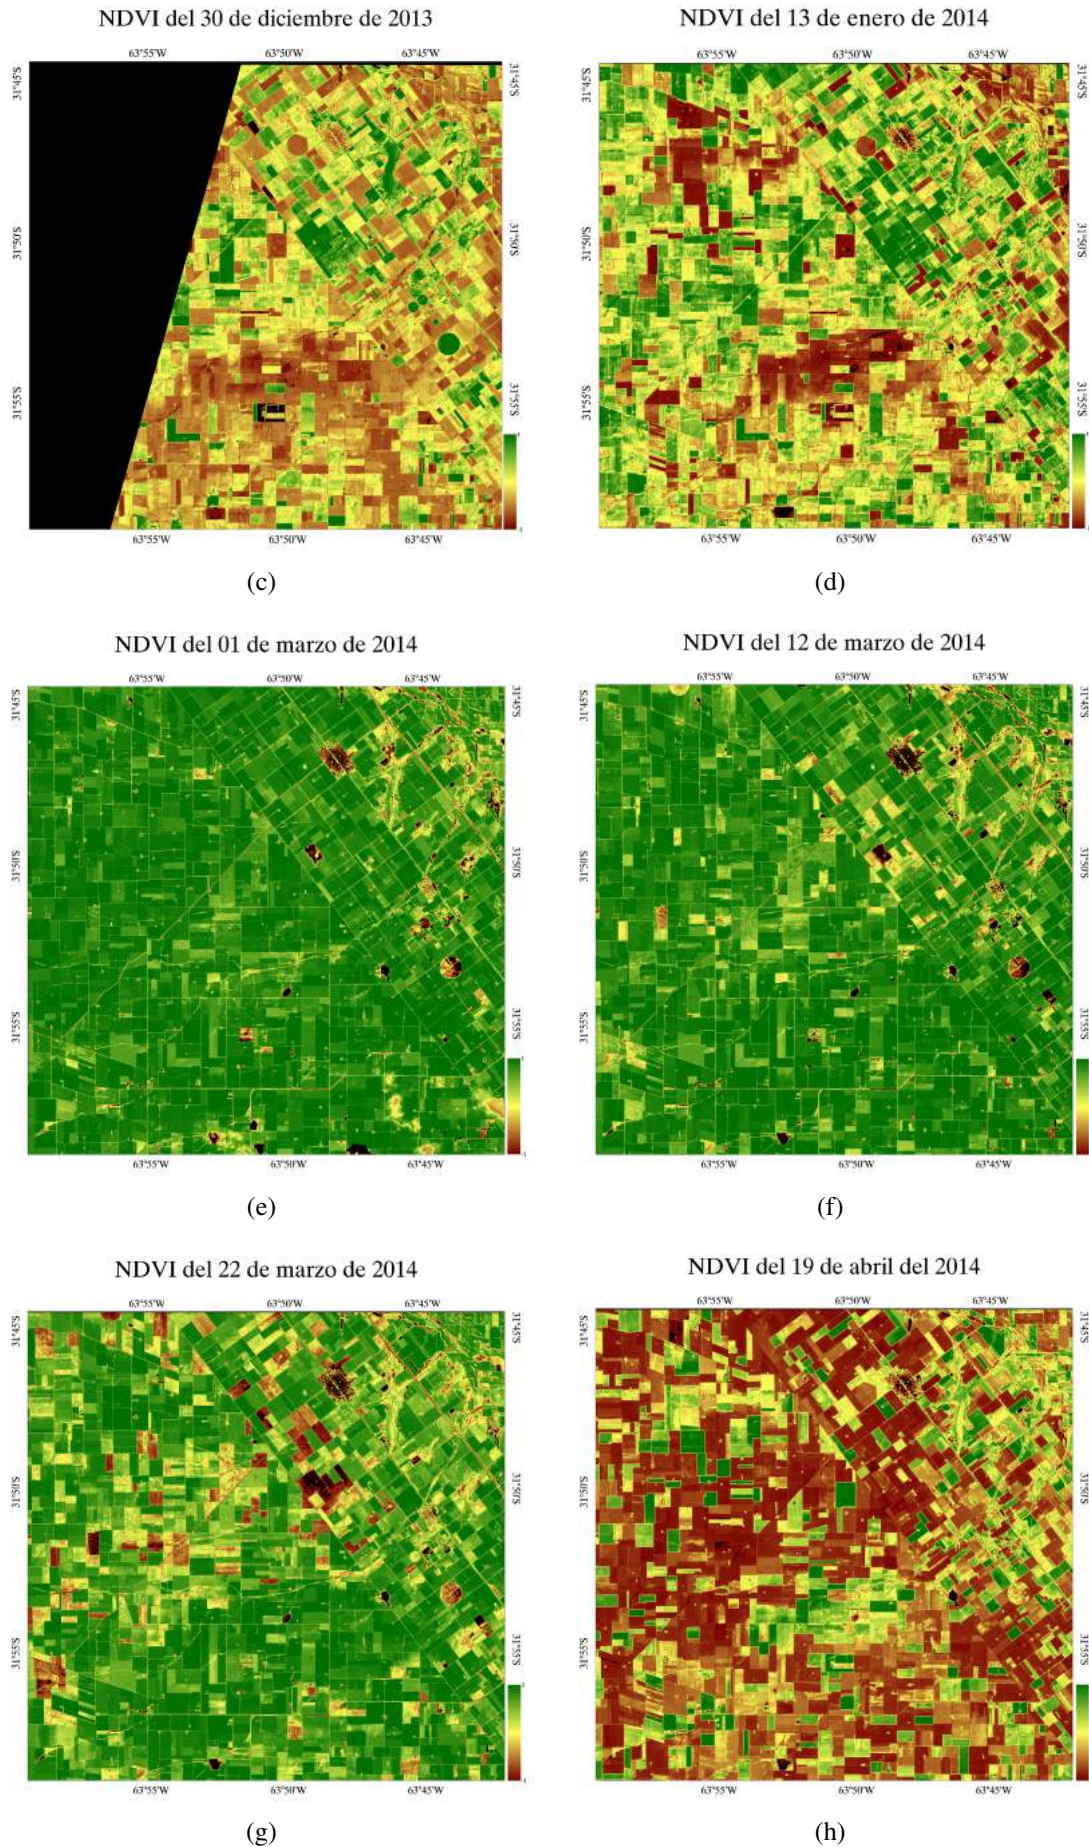


Figura 4.8: Evolución del NDVI en la campaña agrícola 2013-2014, desde octubre a abril, en el departamento Río Segundo, Córdoba.

Los valores de NDVI más elevados para el área de estudio, se registraron, en el mes de marzo. La media más elevada, con un NDVI del 0,89 para la soja, se observó el 01 de marzo. Mientras que para el maíz, en la fecha del 12 de marzo, con un NDVI de 0,92, coincidiendo con el máximo desarrollo fenológico de la soja (R5/R6) y el máximo crecimiento en altura y la aparición de la panoja (VT) en el maíz.

La evolución temporal del NDVI en cada lote mostró, como la literatura sobre el tema explicita, las diferencias respecto de las fechas de siembra y desarrollo de ambos cultivos. En el mes de octubre, la misma, no tuvo una diferencia significativa en los valores del índice debido a que, como ya se mencionó, todos los lotes se encontraban con distintos tipos de rastrojos. En el caso del cultivo de maíz, los lotes fueron sembrados en el mes de diciembre. A principios de diciembre se sembraron los lotes 7 y 10 y a comienzos de la segunda quincena, los lotes 1 y 2. En este caso, la diferencia en el porcentaje de humedad de estos lotes fue notable al momento de la siembra (22 % y 25 % y 15 % y 13 %, respectivamente), lo que sumado a lo anterior y, como muestra la Figura 4.9, se evidenció en los valores más elevados de NDVI en los primeros lotes.




Figura 4.9: Evolución de valores medios de NDVI temporal (octubre-abril) para todos los lotes con cultivo de maíz.

Los lotes con soja, 4, 5, 8 y 9 se sembraron dentro de los primeros 5 días del mes de noviembre, mientras que el 3 y el 6 se sembraron alrededor del 15 del mismo mes (ver Tabla 5.1, Anexo I). En la Figura 4.10, se observa que los valores de NDVI en los lotes 4 y 5, en el mes de diciembre, resultaron más elevados y alcanzaron su máximo antes que los lotes 8 y 9. Como se mencionó en el punto anterior, en el lote 9 se identificó un evento de granizo a principios del mes de diciembre que afectó a un gran porcentaje de vegetación y se evidenció, claramente, el resembrado a principios de enero para este lote. Por el contrario no se tienen datos sobre un posible evento en el lote 8. Los lotes 3 y 6, registraron diferencia entre ellos en los valores de NDVI, a pesar de haber sido sembrados en el mismo tiempo, pero con una misma tendencia.

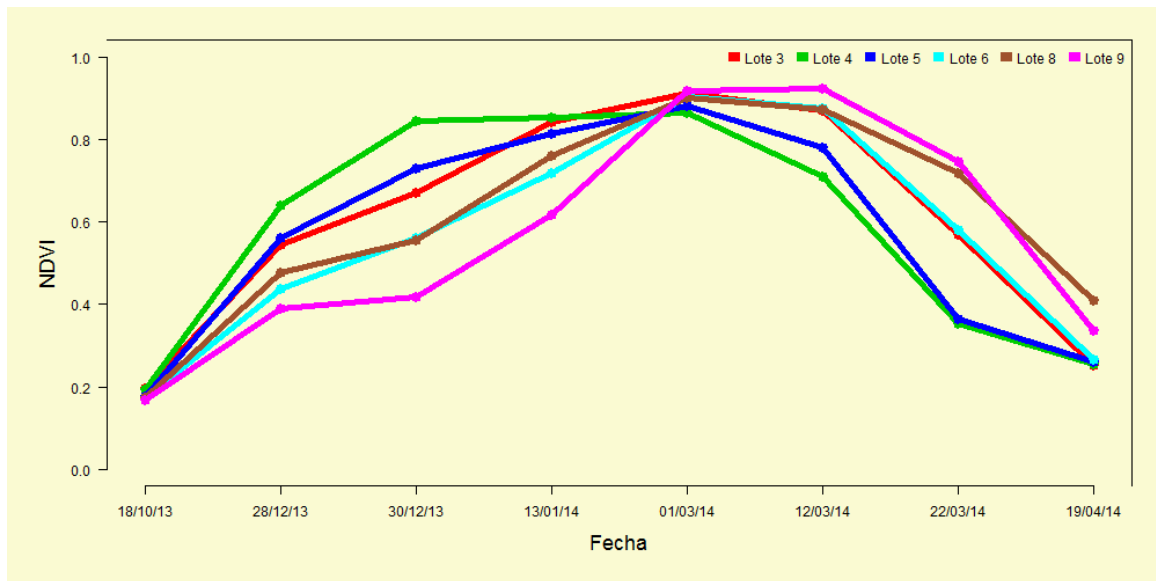


Figura 4.10: Evolución de valores medios de NDVI temporal (octubre-abril) para todos los lotes con cultivo de soja.

De la misma forma que [113], los valores máximos y mínimos del índice estuvieron directamente relacionados con el desarrollo fenológico de los cultivos. Asimismo, [6] demostraron que el comportamiento de índices de vegetación de un determinado píxel a lo largo de una estación de crecimiento, permite dar cuenta de la dinámica de los cambios estacionales de la vegetación. Farrell (2012) [114] observó que los valores de NDVI para el maíz presentan la mejor relación con la altura de la planta y el rendimiento de grano y [115] relacionaron valores de NDVI con temperatura superficial (LST) en lotes de soja en distintas etapas de su ciclo y concluyeron que esta relación no es un buen indicador del contenido de humedad del suelo cuando el cultivo tiene mayor altura.

Los valores del índice de vegetación mostraron ser sensibles a la estructura, tipo y estadio de los cultivos, lo que los convierte en importantes indicadores de desarrollo de los mismo, tanto a nivel de lote como en grandes extensiones, resultando de gran utilidad para estimar rendimientos de cultivos diferenciados y superficies sembradas, cobertura de la vegetación y algunos indicadores de sustentabilidad de la producción como la productividad primaria vegetal y neta. Asimismo, son cada vez más importantes en la detección áreas afectadas por fenómenos naturales y en la delimitación de heterogeneidad productiva a diversas escalas.

4.4. Identificación y clasificación de coberturas

4.4.1. Relación entre datos ópticos y radar

Reflectancia-Retrodispersión

La relación entre valores de retrodispersión de imágenes SAR y los valores de reflectancia de imágenes ópticas en distintas bandas, arrojaron valores de r entre -0,15 y 0,20, indicando que no existe correlación entre los mismos.

NDVI-Retrodispersión

Al relacionar los valores de NDVI de imágenes ópticas con valores de retrodispersión en ambas polarización de imágenes SAR, se encontró una correlación de 0,75 en maíz para las imágenes del 13 y 14 de enero y 0,64 en soja para la correspondiente al 22 y 23 de marzo para la polarización VV y un R^2 de 0,45 y de 0,36, respectivamente.

Estas fechas se corresponden con una etapa de gran diferenciación de los cultivos en su desarrollo y crecimiento y con valores de NDVI elevados. A principios de enero, el maíz se encontraba en un estadio fenológico general entre V4/V5 y V7/V8 (estados vegetativos) mientras que el desarrollo de la soja era, principalmente, de estadios R1/R2 (inicio de la floración) y llegando a su máximo crecimiento en altura. A fines de marzo, el maíz se encontraba en un estado reproductivo de R3/R4 y la soja iniciaba su madurez y senescencia (R7/R8). Esta diferencia en los cultivos podría verse por el radar debido a la diferencia en la textura de la cobertura vegetal. Lamentablemente, por motivos de limitación de software, no se pudo obtener una imagen de textura que pudiera explicar el supuesto.

4.4.2. Redes neuronales

Imágenes ópticas

Se procedió a la clasificación de cada una de las imágenes mediante la aplicación de las RN con los parámetros descritos en el capítulo anterior. Realizada la clasificación, de la forma indicada y con lotes independientes, se procedió a la validación de la mismas y obtención de las matrices de confusión que permitieron realizar análisis cualitativos y cuantitativos.

Los resultados de las clasificaciones se presentan en orden cronológico y se analizan según las condiciones de los cultivos en la distintas fechas. De esta forma, se muestran en primer lugar, los datos clasificados correspondientes a la imagen del mes de octubre, anterior a la siembra; en el segundo grupo, las dos imágenes clasificadas del mes de diciembre (una de cada sensor) con cultivo recién implantado y gran parte de suelo desnudo; en tercer lugar, se analizaron imágenes correspondieron a los meses de enero y marzo, donde los cultivos analizados ya se encontraban en un grado de desarrollo fenológico más avanzado y cubriendo todo o gran parte del suelo y; por último, la imagen del mes de abril donde gran parte de la soja, principalmente, ya fue cosechada y vuelve a verse rastrojo de ese cultivo.




Figura 4.11: Clasificación de la imagen SPOT 5 de octubre de 2013, anterior a la siembra de cultivos de grano grueso.


En la clasificación resultante de la primera fecha y según los datos de la matriz de confusión, la clase suelo y rastrojo de soja obtuvieron la mayor proporción de los píxeles totales clasificados (42346), con un 35,4 % y 33,5 %, respectivamente. Si bien esto es coherente para la fecha, en el caso de la primera clase, el 98,6 % de ese 35 % se clasificó por comisión (rastrojo de maíz). De las seis clases consideradas, cinco dieron un porcentaje muy alto de píxeles bien clasificados según la verdad de terreno (Anexo III), la quinta clase correspondió al rastrojo de maíz que fue clasificado, casi en su totalidad, como suelo desnudo [88]. Esto coincide y reafirma lo expuesto por Daughtry [116], en que la discriminación entre residuos de cultivo y suelo presenta dificultades cuando se usan reflectancias en longitudes de onda visible e infrarrojo cercano. Por otro lado y, como se ve en la Figura 4.11 la distribución de la clasificación, en el total de la imagen (7.406.352 píxeles), fue del 76,1 % (56361,9 ha) de rastrojo de soja, 10,0 % de suelo y 9,6 % de la clase otros (ver Anexo).

Para el mes de diciembre, en la Figura 4.12 se compararon, también, las clasificaciones de ambos sensores ópticos para una misma fecha donde los cultivos considerados fueron sembrados poco tiempo antes de estas tomas y se encontraban en emergencia. La imagen de SPOT 5 fue mejor clasificada que Landsat 8, con la mayor cantidad de píxeles bien clasificados en soja (88,0 % contra 56,8 %), sorgo (84,1 % contra 20,5 %) y ciudad (centros urbanos, casas rurales, pavimento) (97,0 % contra 75,4 %), no así en el resto las clases: maíz (67,0 % contra 87,1 %), suelo (39,8 % contra 92,9 %), agua (63,2 % contra 65,4 %) y otros (21,5 % contra 45,8 %).

La distribución de clasificación de los píxeles totales de la imagen SPOT fue de un 30,4 % de maíz y un 22,4 % de soja para la totalidad de la imagen, aunque algo subestimados respecto de los


porcentajes reales (ya que la superficie sembrada no ocupa la superficie completa), este resultado, no se corresponde con la relación real de ha sembradas de estos cultivos para la fecha. Lo mismo sucede en la imagen Landsat de la misma fecha, sin embargo, en ésta un gran porcentaje de los píxeles de soja son confundidos con maíz (error de omisión). Como se vio en el análisis de las firmas espectrales, ambos cultivos en esta etapa (estadios vegetativos), tienen bajos valores de NDVI (4.8) pueden parecerse espectralmente y, además, tener gran influencia del suelo y/o de rastrojos anteriores debido a la poca cobertura. Algunos autores, como [117], ya comprobaron que los residuos de cultivos pueden ser más brillantes que el suelo en todas las longitudes de onda ni bien realizada la cosecha y, después, a medida que los residuos se descomponen pueden volverse más opacos que el suelo. Aseguran, que el contenido hídrico del complejo suelo-residuo también influye sobre las propiedades espectrales de la cubierta.

Landsat 8 del 28 de diciembre de 2013



(a)

Spot 5 del 30 de diciembre de 2013




(b)

Figura 4.12: Clasificación de las imágenes SPOT 5 y Landsat 8 del 28 y 30 de diciembre de 2013, posterior a la siembra de cultivos de grano grueso.


En los meses donde la vegetación se encontraba en estadios más avanzados, la mejor clasificación resultó en la imagen del primero de marzo aunque, salvo en las clases sorgo y otros, el resto tuvieron la mayor cantidad de píxeles bien clasificados en todas las fechas. En las imágenes del 13 de enero y del 01 de marzo, la clase otros fue clasificada por omisión como sorgo, mientras que en las imágenes del 12 y 22 de marzo, el sorgo fue clasificado por omisión como soja. La proporción de píxeles de toda la imagen clasificados como maíz fue de 39,7 % en la primera y, luego, se encontraron valores de 16,5 %, 17,8 % y 18,3 %, esta diferencia en la imagen de enero, puede deberse a la alta proporción de píxeles de la clase otros que se clasificaron por comisión. La proporción de los píxeles de las imágenes de estas fechas clasificados como soja, en orden temporal, fueron en aumento con el 42,6 %, 54,5 %, 62,1 % y 64,2 % y, coherentemente con lo esperado, registraron las máximas proporciones de coberturas en todas estas. La proporción de píxeles de sorgo se mantuvo más o menos constante en proporciones mucho menores a los otros cultivos y mayores a las clases de ciudad (centros urbanos, casas rurales, pavimento, etc.), agua y suelo en la mayoría de los casos (6,3 %, 7,5 %, 7 %, 6,2 %). La proporción de suelo desnudo fue muy baja y en detrimento en estas fechas con 6,4 %, 2,5 %, 2,7 %, 1,8 %, (Figura 4.13).

Landsat 8 del 13 de enero de 2014




(a)

Spot 5 del 01 de marzo de 2014




(b)

Spot 5 del 12 de marzo de 2014



(c)

Spot 5 del 22 de marzo de 2014



(d)

Figura 4.13: Clasificación de las imágenes SPOT 5 y Landsat 8 de los meses de enero y marzo de 2014, en pleno desarrollo de los cultivos.

Es importante destacar que, más allá de las proporciones de píxeles clasificados que se tuvieron en cada imagen para cada cultivo analizado, las clasificaciones de los lotes a lo largo del tiempo fue coherente en su mayoría y, aquellos señalados como soja y maíz, fueron los mismos en todas las fechas.

Por último, la clasificación de la imagen del 19 de abril resultó en una alta proporción de píxeles bien clasificados en general, sólo la clase otros se confundió con la soja. En la distribución de la clasificación de esta imagen y respecto de las anteriores, se observó una disminución en los píxeles de soja (51,8 %) y un aumento en el área clasificada como suelo desnudo (8,0 %) debido al comienzo de la cosecha de soja. De la misma forma, se verifica un leve incremento del área de maíz (19,7 %) y de sorgo (9,5 %), que podría deberse a una confusión de las clases debido a la entrada en senescencia de los cultivos (Figura 4.14).

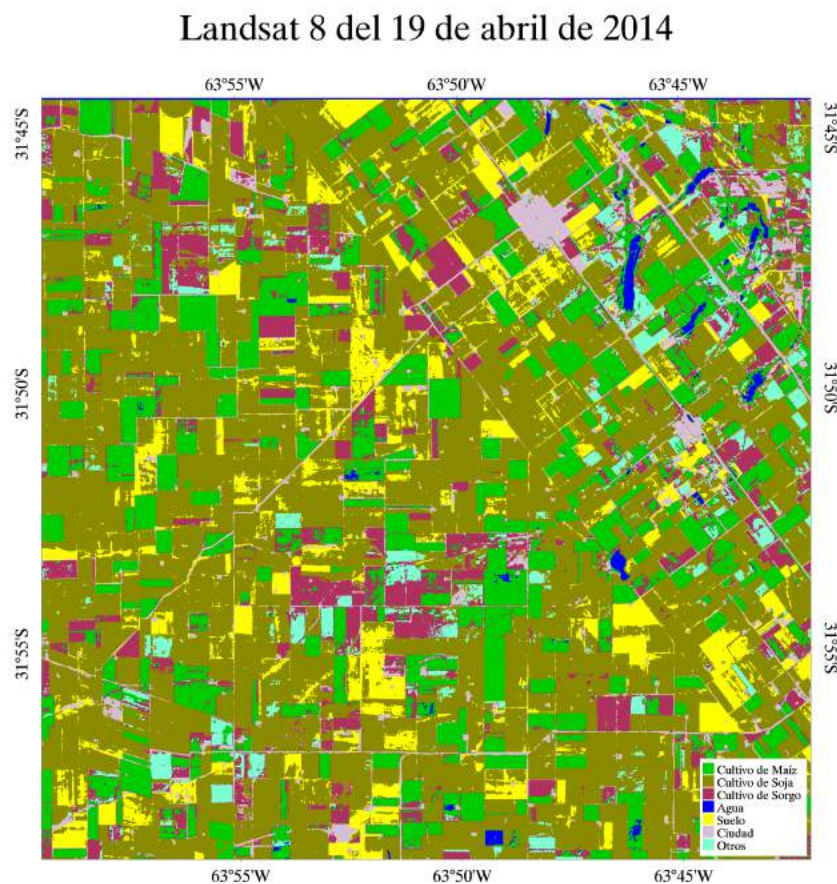


Figura 4.14: Clasificación de la imagen Landsat 8 de abril de 2014, con avanzado estado fenológico de los cultivos y comienzo de la cosecha.

Cuantitativamente y de forma más general, los resultados de las clasificaciones estuvieron dentro de los rangos de índice kappa de moderado a muy bueno ($k=0,41$ a $k=1,00$), obteniéndose el coeficiente más elevado para la imagen SPOT 5 del 10 de octubre de 2013 ($k=0,9$) y el más bajo para la imagen Landsat 8 del 28 de diciembre de 2013 ($k=0,5$). Como se mencionó, en el caso de la primer imagen, las respuestas de los distintos rastrojos y el suelo hacen que los datos de la imagen sean homogéneos y, por ende, la clasificación arroja mayor exactitud, mientras que, en el caso de la imagen Landsat, la pérdida de resolución en el proceso de co-registro pudo haber causado menor concordancia entre las clases de interés y la verdad de terreno (Tabla 4.6). De aquellas imágenes donde los cultivos se

encontraban en su máximo verdor, la correspondiente a la fecha del primero de marzo fue clasificada con un kappa de 0,8, dando una superficie sembrada con soja de 40.000 has y 12.000 has de maíz.

Tabla 4.6: Matrices de precisión de las clasificaciones para distintas imágenes.

Imagen	Clasificación	Maiz	Soja	Sorgo	Agua	Suelo	Ciudad	Otros	Precisión	Kappa	Resultado
18/10/2013	Porcentaje	1,17	99,97		89,86	97,02	91,87	99,72	91,9	0,9	Muy Buena
	Comisión	12,50	3,09		0,48	15,91	0,26	7,89			
	Omisión	98,83	0,03		10,14	2,98	8,13	0,28			
28/12/2013	Porcentaje	87,1	56,81	20,45	65,38	92,85	75,4	45,78	65,1	0,5	Buena
	Comisión	39,69	36,81	40,8	5,94	29,98	10,42	53,4			
	Omisión	12,9	43,19	79,55	34,62	7,15	24,6	54,22			
30/12/2013	Porcentaje	67,06	88,05	84,14	63,18	39,78	96,96	21,49	75,3	0,7	Buena
	Comisión	13,96	26,99	47,42	6,72	6,95	10,89	31,59			
	Omisión	32,94	11,95	15,86	36,82	60,22	3,04	78,51			
13/01/2014	Porcentaje	65,29	80,64	89,63	89,7	66,89	78,01	0,0	74,7	0,7	Buena
	Comisión	36,37	20,66	26,05	4,6	5,36	40,69	100,0			
	Omisión	34,71	19,36	10,37	10,3	33,11	21,99	100,0			
01/03/2014	Porcentaje	78,52	92,51	69,76	93,87	75,6	81,4	28,38	82,9	0,8	Muy Buena
	Comisión	9,42	14,56	29,36	0,62	19,72	20,26	77,41			
	Omisión	21,48	7,49	30,24	6,13	24,4	18,6	71,62			
12/03/2014	Porcentaje	72,53	86,32	40,84	81,87	59,45	92,84	44,26	75,2	0,7	Buena
	Comisión	14,75	20,26	60,9	10,02	15,73	31,07	67,04			
	Omisión	27,47	13,68	59,16	18,13	40,55	7,16	55,74			
22/03/2014	Porcentaje	70,42	92,62	14,15	81,99	81,25	77,32	36,87	73,2	0,6	Buena
	Comisión	15,92	29,22	73,68	6,37	32,78	20,29	24,48			
	Omisión	29,58	7,38	85,85	18,75	46,01	22,68	63,13			
19/04/2014	Porcentaje	76,51	76,86	72,43	77,27	98,21	98,72	27,36	81,7	0,8	Muy Buena
	Comisión	17,38	20,24	20,63	0,61	27,12	9,24	27,19			
	Omisión	23,49	13,84	27,57	22,73	1,79	1,28	72,64			


Distintos autores han probado la precisión de las Redes Neuronales Artificiales en clasificación de cultivos y el uso de suelo con imágenes ópticas. En el área de estudio, se logró una clasificación de cobertura del suelo con MODIS, con un índice kappa de 40 al 85 %, aplicando diversos modelos con redes neuronales [27]. Hui Yuan [118] probó una combinación de parámetros para una selección óptima de la arquitectura de la red, obteniendo resultados con un coeficiente de 88 % en imágenes Landsat.

Este estudio arrojó muy buenos resultados de clasificación de cultivos con esta metodología en imágenes ópticas de una fecha, pudiendo visualizar la variación temporal de las coberturas vegetales en la zona de estudio (rastrajo, suelo, cultivos) y estimar la proporción de tierras sembradas con estos cultivos razonablemente. Cabe aclarar, que las diferencias en las fechas de siembra de ambos cultivos facilitó en gran parte la diferenciación de los mismos y, por ende, la clasificación de las imágenes.


Imágenes radar

La clasificación con redes neuronales de ENVI para imágenes COSMO SkyMed resultó en una y dos clases cuando se procesó una imagen particular, asignando todos los píxeles a diversas clases según la fecha utilizada. Debido a esto, se decidió clasificar temporalmente estos datos, es decir, con una serie de imágenes de distintos estados fenológicos del cultivo (fechas diferentes de la misma campaña). Teniendo en cuenta sólo imágenes con cultivo (diciembre a mayo) y, aquellas que abarcaban completamente el área de estudio quedando las correspondientes al 17 de diciembre; 14 y 30 de enero; 23 de febrero; 23 de marzo y 22 de mayo, se probaron diversas combinaciones con los mismos parámetros usados para ópticas pero con 1000 iteraciones.

Según el análisis de las matrices de precisión, las dos mejores clasificaciones (Figura 4.15) se obtuvieron con ambas polarizaciones, habiendo una diferencia en la precisión de 41 % a 43 % y en el coeficiente kappa de 0,29 y 0,32. En el primer caso, corresponde a 6 imágenes radar clasificadas temporalmente sin tener en cuenta dirección de órbita, enfoque y ángulo. El segundo, a 4 imágenes (17 de diciembre, 14 de enero, 23 de marzo y 22 de mayo) con órbitas ascendente, enfoque de derecha y ángulo aproximado de 43° (Figura 4.15).



(a) Clasificación temporal de imágenes 6 imágenes COSMO SkyMed en ambas polarizaciones sin tener en cuenta dirección de órbita, enfoque y ángulo.



(b) Clasificación temporal de imágenes 4 imágenes COSMO SkyMed en ambas polarizaciones con la misma dirección de órbita, enfoque y ángulos aproximados.

Figura 4.15: Clasificación temporal de imágenes COSMO SkyMed con ENVI.

Debido a que los resultados no fueron los esperados, se procedió a clasificar con la misma metodología de Redes Neuronales pero utilizando un programa en R (Anexo III). Las clases que se definieron fueron las mismas que para la anterior clasificación y se probaron distintas combinaciones de imágenes. Al intentar el procesamiento en las condiciones anteriores, el software arrojó un error de memoria, motivo por el cual se recortó aún más el área de las imágenes quedando una superficie de 2070 x 2643 píxeles. Al igual que en el caso anterior, se probaron diversas combinaciones de fechas y bandas. Contrariamente a lo que se obtuvo con ENVI, la mejor clasificación fué aquella con la mayor cantidad de bandas probadas, 6 imágenes en ambas polarizaciones, sin tener en cuenta dirección de órbita, enfoque y ángulos y con imágenes enteras de la época de cultivo, con un coeficiente kappa de 0,59.

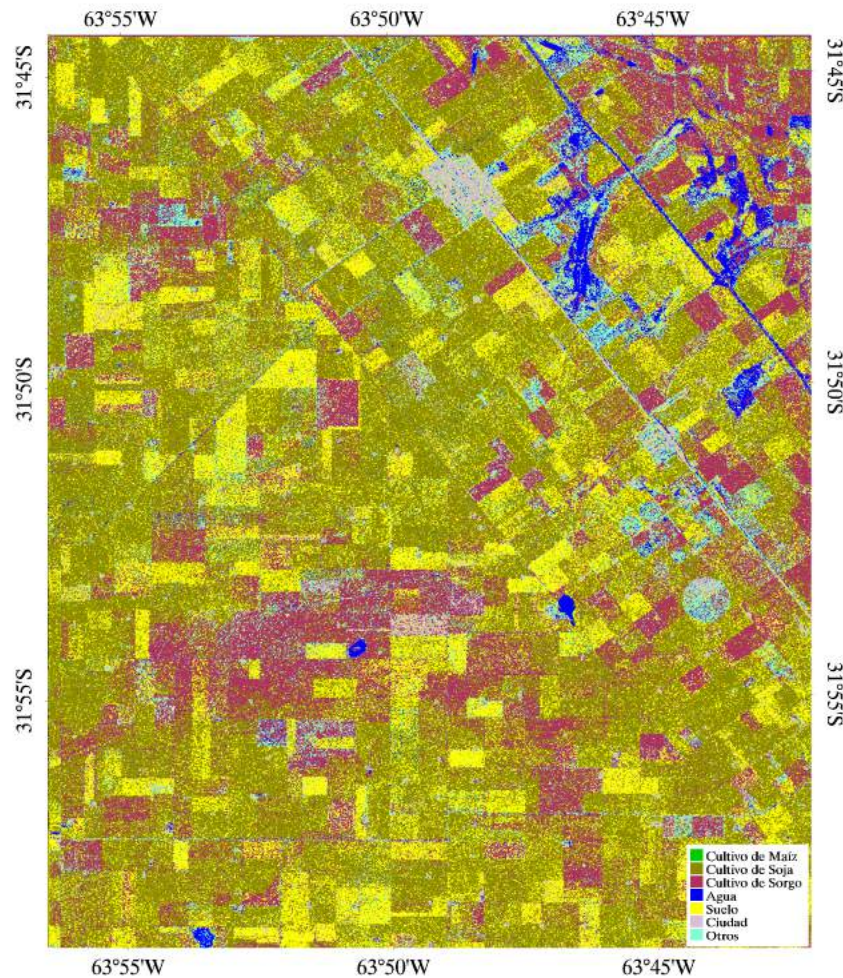


Figura 4.16: Clasificación temporal de 6 imágenes COSMO SkyMed en polarización VV con R.

En la Tabla 4.7, se presentan la cantidad de píxeles bien clasificados con el algoritmo de RN de R y la cantidad clasificada por omisión en cada una de las clases restantes. A excepción del cultivo de maíz, el resto de las clases tuvieron la mayor cantidad de píxeles bien clasificados. En cuatro de las siete clases, los píxeles que debieran haberse asignado a éstas, se confunden en alta proporción con píxeles de la clase ciudad (centros urbanos, casas rurales, pavimento). Sin embargo, esto no se visualiza en la imagen debido a que, estos píxeles mal clasificados, forman pequeñas agrupaciones esparcidas en toda el área. El cultivo de maíz, por otra parte, sólo tuvo píxeles clasificados por comisión, es decir, incluidos aquí por error del algoritmo.

Tabla 4.7: Porcentaje de píxeles bien clasificados y clasificados por omisión en cada clase con algoritmo de Redes Neuronales en R.


Soja	Sorgo	Agua	Suelo	Ciudad	Otros
Soja 38,97	Sorgo 38,42	Agua 50,96	Suelo 32,34	Ciudad 14,65	Otros 36,45
Otros 5,72	Ciudad 7,56	Ciudad 3,67	Ciudad 4,77	Suelo 3,99	Ciudad 18,48

Por último, se clasificó con el algoritmo de redes neuronales de ENVI y los mismos parámetros que para las clasificaciones anteriores, aquellas imágenes radar con misma dirección, enfoque y ángu-


lo y las bandas del rojo e IRC de la imagen SPOT 5 del 1 de marzo. Sólo se tuvo en cuenta esta imagen por ser la que resultó mejor clasificada anteriormente. Se probaron las siguientes combinaciones de fechas y polarizaciones de imágenes radar:

- Todas las imágenes en ambas polarizaciones.
- Todas las imágenes en polarización VV.

En la Figura 4.17 se muestran, de forma comparativa, las clasificaciones obtenidas con la integración de ambos sensores.



(a) Ambas polarizaciones.



(b) Polarización VV.

Figura 4.17: Clasificación con RN de imágenes COSMO SkyMed del área de estudio y bandas del rojo e infrarrojo cercano de imagen SPOT 5 del 1 de marzo.

Como se observa en la Tabla 4.8, el índice de kappa en (a) no superó la categoría de moderado (0,41-0,6) mientras que en (b) correspondió a la categoría de bueno (0,61-0,8), siendo el mejor resultado obtenido con imágenes SAR.

Tabla 4.8: Exactitud global y Coeficiente Kappa de cada casificación de COSMO SkyMed y SPOT 5.

Imágenes	Coeficiente Kappa	Exactitud global (%)
Todas las imágenes en ambas polarizaciones.	0,58	64,8
Todas las imágenes en polarización <u>VV</u> .	0,50	58,1

La mayor precisión, coeficiente kappa y la mayor cantidad de píxeles bien clasificados, se obtuvieron del stack de imágenes COSMO SkyMed de imágenes en ambas polarizaciones. En esta, fueron bien clasificadas 5 de las clases, confundándose las clases sorgo y otros con la clase soja (4.9).

Tabla 4.9: Porcentaje de píxeles bien clasificados en cada clase y clase con más píxeles por omisión, en clasificaciones de distintas combinaciones de imágenes COSMO SkyMed y bandas del rojo e infrarrojo cercano y de la imagen SPOT 5 del 1 de marzo.

Todas las imágenes en ambas polarizaciones						
Maíz	Soja	Sorgo	Agua	Suelo	Ciudad	Otros
Maíz 44,2	Soja 83,6	Sorgo 43,2	Agua 94,3	Suelo 39,8	Ciudad 91,2	Otros 23,7
Sorgo 20,3	Sorgo 9,05	Soja 52,1	Otros 2,2	Ciudad 24,8	Suelo 7,3	Soja 46,2
Todas las imágenes en polarización VV						
Maíz	Soja	Sorgo	Agua	Suelo	Ciudad	Otros
Maíz 0,4	Soja 79,7	Sorgo 51,8	Agua 88,2	Suelo 21,2	Ciudad 91,6	Otros 23,2
Otros 48,6	Sorgo 11,6	Soja 39,7	Otros 6,8	Ciudad 65,4	Suelo 8,3	Soja 46,2

Satalino et al. ([119] y [120]) realizaron diversos estudios clasificando cultivos de forma multi-temporal con imágenes satelitales COSMO SkyMed StripMap PingPong, obteniendo altos valores de precisión e índice kappa. Sin embargo, a diferencia de este trabajo, las polarizaciones utilizadas fueron HH/HV y los ángulos de incidencia mucho más bajos. Por otro lado, estudios de uso de suelo con integración de datos ópticos y radar son basados, en general, en el uso de sensores con cuatro polarizaciones y satélites ópticos como Landsat, SAC-C y SPOT ([121], [122], [123], [124]), obteniendo buenos resultados en evaluación de desmontes, estado de vegetación, cobertura, clasificación de cultivos de secano y bajo riego, entre otros.

En este estudio, las clasificaciones de cultivos de soja y maíz con imágenes COSMO SkyMed, no mostraron resultados del todo satisfactorios para el uso de éstas en análisis agrícolas. Con las metodologías propuestas y aplicando el clasificador supervisado de RN, la banda X en polarizaciones HH/VV, no son aptas para el reconocimiento y/o monitoreo de estas especies vegetales. La clasificación de imágenes radar logra diferenciar más de una clase sólo cuando se realiza sobre un conjunto de imágenes temporales. En este caso, el algoritmo de redes neuronales en R-Estadística mejoró sustancialmente la clasificación de imágenes SAR respecto del software ENVI, obteniendo resultados de precisión de débil a moderada. Asimismo, el análisis conjunto de imágenes ópticas y radar, en una combinación de datos temporales y bandas roja e infrarroja, aumentó el porcentaje de precisión y el coeficiente kappa de la clasificación a un nivel de bueno.

4.4.3. Distancia estocástica de Hellinger

Con el fin de identificar diferencias entre cultivos en imágenes SAR, se calcularon las distancias Hellinger entre todos los lote sembrados con el mismo cultivo y entre aquellos con cultivos diferentes (4 lotes de maíz y 6 de soja). En la Tabla 4.10, se presentan las distancias obtenidas para el cultivo de maíz en aquellas imágenes cuya fecha coincidió con las ópticas, en ambas polarizaciones (26 de octubre, 17 de diciembre, 23 de marzo y 22 de mayo). No se tuvieron en cuenta las imágenes de los meses de febrero y abril ya que muchos lotes cayeron fuera del área de cobertura de la misma.

Tabla 4.10: Distancias de valores de retrodispersión entre cuatro lotes con cultivos de maíz en polarización VV y HH; medias y desvíos estándares de esas distancias.

Fecha Imagen	Distancias de cultivos de maíz en polarización VV						Media	Desvío Estándar
	L1-L2	L1-L7	L1-L10	L2-L7	L2-L10	L7-L10		
26/10/2013	0.21	0.61	0.62	0.19	0.23	0.01	0.31	0.25
17/12/2013	0.01	0.02	0.00	0.00	0.02	0.03	0.02	0.01
14/01/2014	0.01	0.42	0.25	0.44	0.25	0.03	0.23	0.18
23/03/2014	0.01	0.00	0.03	0.01	0.08	0.03	0.03	0.03

Fecha Imagen	Distancias de cultivos de maíz en polarización HH						Media	Desvío Estándar
	L1-L2	L1-L7	L1-L10	L2-L7	L2-L10	L7-L10		
26/10/2013	0.28	0.72	0.76	0.18	0.19	0.00	0.35	0.28
17/12/2013	0.00	0.00	0.01	0.00	0.01	0.03	0.01	0.01
14/01/2014	0.02	0.25	0.10	0.13	0.02	0.09	0.10	0.08
23/03/2014	0.02	0.04	0.01	0.01	0.00	0.02	0.02	0.01

Las distancias entre la mayoría de los lotes con maíz resultaron en valores cercanos a cero en ambas polarizaciones, encontrándose las mayores discrepancia en la imagen correspondiente al mes de octubre con rastrojo, no superando las medias de estas distancias el valor de 0,35. Esto indicó, que en los estadios avanzados, las diferencias entre lotes del mismo cultivo son despreciables en este tipo de imágenes SAR.

En la Tabla 4.11, se muestran las tablas para ambas polarizaciones con las distancias entre lotes con cultivo de soja.

Tabla 4.11: Distancias de valores de retrodispersión entre cuatro lotes con cultivos de soja en polarización VV y HH, medias y desvíos estándares de esas distancias.

Fecha Imagen	Distancias de cultivos de soja en polarización VV															Media	Desvio Estándar
	L3-L4	L3-L5	L3-L6	L3-L8	L3-L9	L4-L5	L4-L6	L4-L8	L4-L9	L5-L6	L5-L8	L5-L9	L6-L8	L6-L9	L8-L9		
26/10/2013	0.01	0.36	0.11	0.00	0.30	0.34	0.07	0.00	0.27	0.10	0.38	0.01	0.10	0.06	0.31	0.16	0.15
17/12/2013	0.00	0.29	0.45	0.10	0.52	0.29	0.47	0.55	0.10	0.05	0.03	0.10	0.11	0.01	0.15	0.21	0.20
14/01/2014	0.01	0.00	0.18	0.07	0.51	0.02	0.28	0.16	0.63	0.12	0.05	0.40	0.04	0.11	0.28	0.19	0.19
23/03/2014	0.07	0.08	0.10	0.10	0.01	0.00	0.32	0.34	0.04	0.29	0.32	0.05	0.00	0.15	0.16	0.14	0.12

Fecha Imagen	Distancias de cultivos de soja en polarización HH															Media	Desvio Estándar
	L3-L4	L3-L5	L3-L6	L3-L8	L3-L9	L4-L5	L4-L6	L4-L8	L4-L9	L5-L6	L5-L8	L5-L9	L6-L8	L6-L9	L8-L9		
26/10/2013	0.15	0.13	0.00	0.07	0.16	0.00	0.11	0.36	0.00	0.10	0.34	0.00	0.08	0.12	0.00	0.11	0.11
17/12/2013	0.02	0.36	0.11	0.11	0.07	0.11	0.24	0.18	0.24	0.24	0.00	0.01	0.00	0.00	0.01	0.11	0.11
14/01/2014	0.01	0.07	0.14	0.11	0.26	0.10	0.17	0.15	0.29	0.01	0.00	0.06	0.00	0.04	0.07	0.10	0.09
23/03/2014	0.10	0.04	0.04	0.00	0.03	0.02	0.24	0.21	0.11	0.16	0.05	0.13	0.03	0.00	0.01	0.08	0.08

Las distancias medias para todas las fechas, en los lotes de soja, resultaron más elevadas que para el maíz, sobre todo en polarización VV. Sin embargo, estas diferencias no son suficientes para establecer un rango de distancias que diferencien ambos cultivos para una misma fecha analizada y sin tener en cuenta posibles diferencias entre diferentes lotes.

Para la diferenciación entre cultivos se calcularon las distancias de cada uno de los lotes de maíz contra cada uno de los lotes de soja (Figura 4.12) obteniendo como resultado una gran disparidad entre los valores con distancias que fueron desde 0,00 a 0,82 para la polarización VV y 0,87 para la HH, sin relación alguna con la época analizada. Sin embargo, para la polarización VV los valores

medios por imagen dieron resultados mayores a los obtenidos al comparar lotes de un mismo cultivo, no así para la polarización HH.

Tabla 4.12: Distancias de valores de retrodispersión entre lotes con cultivos de maíz y soja en polarización VV y HH; medias y desvíos estándares de esas distancias.

Fecha de la imagen	Distancias entre cultivos de maíz y soja en polarización VV																								Media	Desvio Estándar
26/10/2013	0,77	0,80	0,26	0,52	0,82	0,33	0,37	0,37	0,00	0,11	0,40	0,01	0,04	0,01	0,18	0,02	0,03	0,13	0,01	0,00	0,23	0,05	0,00	0,18	0,24	0,27
17/12/2013	0,53	0,56	0,10	0,01	0,16	0,00	0,54	0,55	0,07	0,00	0,16	0,01	0,38	0,40	0,02	0,00	0,07	0,02	0,59	0,61	0,13	0,01	0,20	0,00	0,21	0,23
14/01/2014	0,59	0,70	0,46	0,21	0,40	0,04	0,62	0,73	0,51	0,40	0,02	0,19	0,04	0,10	0,02	0,06	0,00	0,32	0,14	0,24	0,09	0,00	0,15	0,02	0,25	0,24
23/03/2014	0,10	0,32	0,29	0,00	0,16	0,00	0,18	0,44	0,40	0,01	0,02	0,25	0,11	0,34	0,31	0,00	0,00	0,16	0,03	0,20	0,19	0,03	0,02	0,06	0,15	0,14

Fecha de la imagen	Distancias entre cultivos de maíz y soja en polarización HH																								Media	Desvio Estándar
26/10/2013	0,78	0,61	0,60	0,72	0,87	0,51	0,23	0,05	0,05	0,18	0,40	0,02	0,00	0,11	0,10	0,00	0,08	0,12	0,01	0,10	0,09	0,00	0,11	0,12	0,24	0,28
17/12/2013	0,17	0,32	0,03	0,04	0,06	0,01	0,23	0,40	0,04	0,06	0,09	0,02	0,28	0,46	0,06	0,09	0,12	0,04	0,11	0,24	0,00	0,01	0,02	0,00	0,12	0,13
14/01/2014	0,22	0,24	0,05	0,03	0,05	0,00	0,10	0,12	0,00	0,00	0,00	0,03	0,01	0,00	0,11	0,19	0,16	0,30	0,05	0,08	0,01	0,03	0,01	0,12	0,08	0,09
23/03/2014	0,08	0,30	0,22	0,01	0,06	0,02	0,19	0,46	0,37	0,06	0,15	0,09	0,25	0,53	0,44	0,10	0,20	0,13	0,15	0,41	0,32	0,03	0,11	0,06	0,20	0,15

Frery et al. (2011) ([101]), analizaron el contraste de zonas forestales y de pastoreo entre imágenes SAR polarimétricas E-SAR, comparando varios test estadísticos basados en distancias estocásticas encontrando buenos resultados en todos los casos, siendo muy sensibles a valores atípicos en la imagen.

Relación temporal de NDVI y distancias de Hellinger

Se exploraron otras alternativas con el fin de encontrar una relación entre ambos tipos de datos analizando la distancia de Hellinger entre cultivos y lotes del mismo cultivo y su evolución temporal.

Se relacionó la media de las distancias entre valores de retrodispersión de lotes de maíz y de soja en polarización VV de las imágenes SAR, graficadas a través del tiempo, junto a la diferencia entre las medias de NDVI en valor absoluto, de los mismos lotes (Figura 4.18).

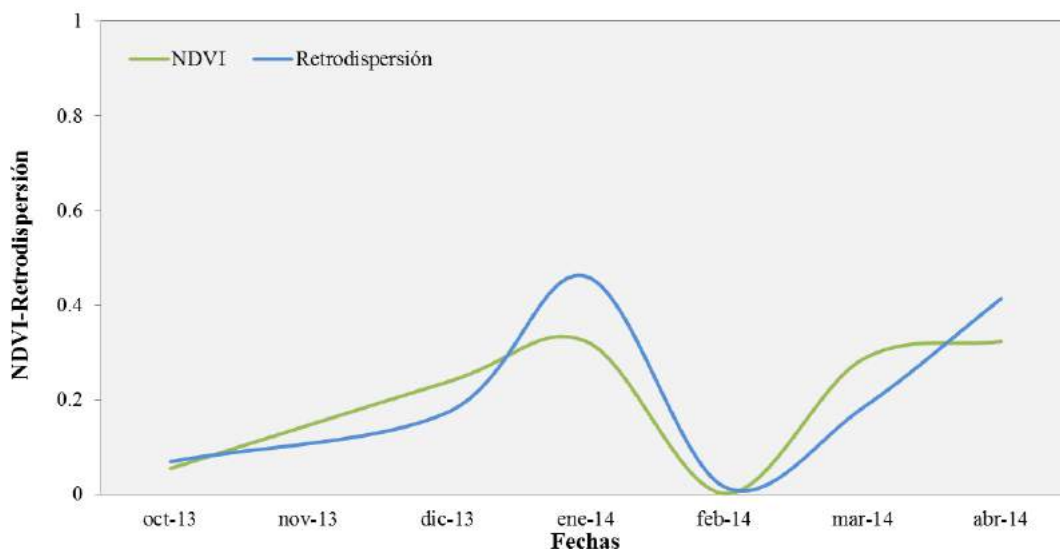


Figura 4.18: Distancia de retrodispersión media y diferencia absoluta entre medias de NDVI entre lotes de maíz y soja.

Se encontró, en este caso, una correlación de $r= 0.87$ y un valor de $R^2=0,70$ en la regresión lineal entre las distancias de retrodispersión media y la diferencia absoluta entre medias de NDVI.

La distancia entre los dos cultivos en valores de retrodispersión sigue la misma tendencia que la distancia de los valores de NDVI entre los mismos, en distintas fechas. En los primeros meses, la soja tiene valores de NDVI más elevados que el maíz, ya que fue sembrado con anterioridad, a finales de febrero principios de marzo, ambos cultivos se encuentran en su máximo crecimiento y, luego, esa diferencia crece nuevamente cuando la soja entre en senescencia y el maíz continúa vigoroso. Lo mismo sucede con la distancia entre los valores de retrodispersión de ambas especies. Esto podría estar ligado a las diferencias de textura de la vegetación que resultó bastante marcada temporalmente.

Autores como Capodici et al. (2013) [40] han demostrado la relación entre valores de IAF (Índice de Área Foliar) y NDVI con valores de retrodispersión de imágenes COSMO SkyMed en polarización cruzada (HV) para cultivos de maíz y alfalfa. En este trabajo, se relacionaron de varias formas los valores de retrodispersión con NDVI con el fin comprobar si existe una posible vinculación de estos a través del tiempo y/o con el crecimiento de la vegetación, que puedan aportar una posible identificación de cultivos con datos SAR en banda X y para estas polarizaciones, sin embargo, los intentos no dieron buenos resultados. Tampoco se encontraron trabajos referidos a la relación de éste índice con distancias estocásticas entre cultivos o la evolución temporal de esa distancia para un mismo cultivo.

Capítulo 5

Conclusiones

De acuerdo con todo lo analizado en este trabajo se puede afirmar que la identificación, discriminación y caracterización de cultivos en imágenes de satélites ópticos, principalmente de soja y maíz, se puede realizar con alta precisión a partir de firmas espectrales, clasificación de imágenes y el análisis de valores de NDVI. En este trabajo se pudo demostrar que el uso conjunto de Landsat 8 (30 metros) y SPOT 5 (10 metros) es efectivo y ambos sensores pueden utilizarse indistintamente para una evaluación temporal de los cultivos. Sin embargo, la resolución temporal del satélite Landsat, sumado a la alta nubosidad en la época de desarrollo de estos cultivos, hicieron imposible el seguimiento de los mismos en todos sus estadios.

A nivel regional, las clasificaciones de alta precisión obtenidas del uso conjunto de imágenes de diversas resoluciones espaciales, permiten el mapeo regular del uso de suelo en grandes regiones, la obtención de datos sobre hectáreas implantadas con diversos cultivos y la medición del grado de cobertura de los suelos, principalmente luego de la cosecha, cuando pueden aplicarse medidas de prevención para la erosión de los mismos. A un nivel local, el cálculo del índice de vegetación de los distintos cultivos, también es útil para predecir rendimientos, diagnosticar la productividad de un lote, seguir la evolución temporal de los cultivos, identificar zonas afectadas por eventos adversos y realizar manejos dirigidos, entre otros.

Por otro lado, en el caso de las imágenes SAR, aplicando distancias estocásticas, es posible identificar la presencia de más de un cultivo en el área de estudio. Sin embargo, no se obtuvieron resultados significativos en la identificación de clases con los métodos propuestos en esta tesis. Pese a esto, se comprobó que las clasificaciones temporales con ambas polarizaciones, aumentan la precisión considerablemente en imágenes de este tipo y, a la vez, esta también presenta resultados que pueden considerarse promisorios cuando se combinan con las bandas del rojo e infrarrojo cercano de una imagen óptica. Se encontró que la estimación de la distancia de Hellinger en retrodispersión podría ser equivalente a las distancia de NDVI entre cultivos.

La desventaja más grande de una clasificación temporal, en especial de áreas extensas, es la limitación de la capacidad hardware y/o software, principalmente en el consumo de memoria. A pesar de esto, el objetivo de esta tesis fue el de clasificar maíz y soja y, con las restricciones consideradas, los resultados permiten concluir que son precisas para satélites ópticos y deben ser necesariamente combinadas y/o desechadas para el caso de imágenes de radar.

En este trabajo, no se encontró correlación alguna entre datos de imágenes ópticas y radar que nos permita descifrar información, proveniente de SAR, sobre los cultivos de la zona.

- Las firmas espectrales, extraídas de imágenes satelitales, permiten la diferenciación entre cultivos de maíz y soja y sus estadios fenológicos. La tendencia de las mismas es similar a aquellas recolectadas a campo con espectroradiómetro.
- Las clasificaciones con imágenes ópticas individuales de toda una campaña agrícola, implementando el algoritmo de ENVI basado en redes neuronales, arrojaron muy buenos resultados con valores de precisión desde buenos a muy buenos.
- La clasificación de imágenes radar se logró implementar sólo con un conjunto de imágenes temporales. En este caso, el algoritmo de redes neuronales en R mejoró sustancialmente la clasificación de imágenes SAR respecto del software ENVI, obteniendo resultados de precisión de débil a moderada. Por otro lado, la distancia estocástica de Hellinger permitió diferenciar la existencia de distintos cultivos, en una determinada fecha, pero no identificar el tipo de cultivo, lo cual abre una línea de trabajo a abordar en el futuro.
- El análisis conjunto de imágenes ópticas y radar, en una combinación de datos temporales y bandas roja e infrarroja, aumentó el porcentaje de precisión y el coeficiente kappa de la clasificación de las imágenes SAR, sin embargo, no alcanzó la precisión de las ópticas.
- El índice de vegetación en imágenes ópticas fue sensible a la estructura, tipo y estadio de cultivos. Permitted diferenciar diferencias extra e intra lotes y cultivos e incluso detectar eventos adversos.
- La distancia estocástica de Hellinger para valores de retrodispersión de cultivos de maíz y soja, en imágenes radar, sigue la misma tendencia que la diferencia absoluta de los valores de NDVI entre los mismos cultivos, en imágenes ópticas de igual fecha. Sin embargo, no se encontró correlación entre la distancia de Hellinger y la diferencia de NDVI, para lotes del mismo cultivo a través del periodo de crecimiento.

Trabajos futuros

El conjunto de datos de campo y de satélites obtenidos en este trabajo representan un potencial insumo para estudios dirigidos a la integración de ellos y la confección de mapas de uso de suelo en la región. En el transcurso de esta tesis han surgido dudas y cuestiones que quedaron fuera de este trabajo pero que podrían ser parte de investigaciones futuras. A continuación se presentan diversos puntos de interés para seguir desarrollando esta temática.

1. Evaluar las metodologías empleadas en este estudio con otros niveles de pre-procesamiento y tratamiento de los datos SAR.
2. Incorporar y comparar imágenes radar con distintas configuraciones de polarización.
3. Estudiar la influencia de la estructura y textura de la vegetación en la respuesta de retrodispersión y su relación con los datos ópticos.
4. Correlacionar datos de retrodispersión con otros índices de la vegetación.
5. Analizar cuáles son los cambios en la estructura de la vegetación que producen variaciones significativas en las medidas de similitud (como las distancias estocásticas propuestas por Frery, 2013.)

6. Mejorar la eficiencia de uso de memoria del algoritmo de redes neuronales en R y probar otras combinaciones de bandas para clasificación, así también como la integración de datos radar y ópticos.
7. Implementar clasificaciones temporales de NDVI aumentando el número de firmas fenológicas de diferentes coberturas, teniendo más de una campaña agrícola. Con las mismas, analizar la forma de inferir valores de índice verde de datos satelitales faltantes.

ANEXO I

En este anexo se presentan la tabla de datos relevados a campo durante la campaña agrícola 2013-2014, de fechas cercanas a las imágenes ópticas, en el marco del proyecto "Desarrollo, evaluación y aplicación de modelos para estimar variables agronómicas." aprobado y subsidiado por Secyt-UNC, que se lleva a cabo en la Facultad de Ciencias Agropecuarias.


Tabla 5.1: Datos relevados a campo en fechas cercanas a las imágenes ópticas.

Fechas	Lotes Rastrojo Cultivo	1	2	3	4	5	6	7	8	9	10
		Soja Maiz	Soja Maiz	Maiz Soja	Maiz Soja	Soja Soja	Soja Soja	Soja Maiz	Soja Soja	Soja Soja	Soja Maiz
	Fecha de siembra	14-18 de diciembre	15 de diciembre	15 de noviembre	5-6 de noviembre	5 de noviembre	13 de noviembre	1-6 de diciembre	4-5 de noviembre	5 de noviembre	2-4 de diciembre
17/12/2013	Fenología			V3	V4	V4	V4	V1	V1	V4	Vc
	Altura (cm)			18	25	23	19	17	24	15	17
	Plantas x m			20	23	23	13	4	15	16	4
	Humedad (%)	17,88	16,92	20,18	17,98	22,25	17,26	15,24	15,48	18,90	18,63
27/12/2013	Fenología	V2	V3	V6-V7-R1	V7-R1	V7-V8-R1	V6-V7-V8-R1	V4	V6-V7-R1	V6-V7-R1	V4
	Altura (cm)	9	12	24	34	34	29	34	33	28,5	41
	Plantas x m	3	2,5	16	22	24	13	3,5	15	18	4
	Humedad (%)	14,71	13,36	14,85	12,81	14,19	15,08	14,30	12,77	12,80	14,22
14/01/2014	Fenología	V4-V5	V4-V6	R1-R2	R1-R2	R3	R2	V7-V8	R2		V7-V8
	Altura (cm)	68	68	60	73	64	65	136	63	52	149
	Plantas x m	4	3	16	24	22	14	3	14	19	3
	Humedad (%)	15,74	12,59	11,45	15,73	15,59	14,96	15,19	11,85	12,58	13,47
27/02/2013	Fenología	R1-R2	R3	R6	R5-R6	R6	R5-R6	R4	R6	R5-R6	R4
	Altura (cm)	253	257	87	104	89	83	229	81	87	269
	Plantas x m	2,9	2,6	15	19	22	13	2,5	11	13	3
	Humedad (%)	24,08	25,69	26,91	27,07	24,28	26,05	25,46	24,35	23,83	28,36
13/03/2014	Fenología	R3-R4	R4	R6	R6 - R7	R6 - R7	R6	R4-R5	R6	R6	R4-R5
	Altura (cm)	263	254	87	97	81	81	236	81	83	260
	Plantas x m	3	3	14	23	21	12	3,4	11	13	3,2
	Humedad (%)	25,31	23,26	22,07	21,18	22,60	23,90	21,75	20,66	23,65	26,06
28/03/2014	Fenología	R4	R4	R7	R8	R8	R8	R4-R5	R8	R7	R4-R5
	Altura (cm)	256	257	79	93	73	78	232	68	73	267
	Plantas x m	3,5	2,5	15	21	20	12	3	12	10,25	3
	Humedad (%)	19,43	20,82	20,65	20,44	23,94	24,05	20,95	21,69	21,63	20,57
15/04/2014	Fenología	R4	R5	R8	Cosechado	Cosechado	Cosechado	R5-R6	Cosechado	Cosechado	R5
	Altura (cm)	262,5	261	80				230			258
	Plantas x m	4	3	16				3			3,3
	Humedad (%)	27,27	21,39	21,35	21,35	21,74	22,32	22,06	23,23	22,47	23,28


ANEXO II

En este apéndice se muestra la estadística descriptiva de los lotes seleccionados en el estudio y presentados en el Capítulo IV, tanto para imágenes ópticas como radar, así también como los resultados de los test de normalidad aplicados a los datos SAR. Asimismo, se presentan los gráficos box-plot de los datos estadísticos correspondientes a todos los lotes e imágenes analizadas durante el desarrollo de esta tesis y que no fueron presentados anteriormente.


Imágenes ópticas




(a) Lote 1




(b) Lote 2




(c) Lote 3




(d) Lote 4




(e) Lote 5




(f) Lote 6




(g) Lote 7



(h) Lote 8




(i) Lote 9




(j) Lote 10

Figura 5.1: Box-plot lotes relevados a campo para distintas fechas y tipos de rastrojos y cultivos en imágenes SPOT 5 y Landsat 8.


Imágenes radar




(a) Lote 1




(b) Lote 2




(c) Lote 3




(d) Lote 4




(e) Lote 5




(f) Lote 6




(g) Lote 7



(h) Lote 8



(i) Lote 9



(j) Lote 10

Figura 5.2: Box-plot de lotes revelados a campo para distintas fechas y tipos de rastros y cultivos en imágenes COSMO SkyMed.

Tabla 5.4: Resultados de test de distribución normal de Shapiro-Wilk(estadístico D y p-valor) para imágenes COSMO SkyMed.

Imágenes COSMO SkyMed	Banda	Lote 3			Lote4			Lote 16		
		W	p-valor	Normalidad	W	p-valor	Normalidad	W	p-valor	Normalidad
31/08/2013	VV	0,88	0,00	No Acepta	0,88	0,00	No Acepta	0,87	0,00	No Acepta
	HH	0,86	0,00	No Acepta	0,91	0,00	No Acepta	0,90	0,00	No Acepta
01/10/2013	VV	0,87	0,00	No Acepta	0,89	0,00	No Acepta	0,66	0,00	No Acepta
	HH	0,87	0,00	No Acepta	0,90	0,00	No Acepta	0,63	0,00	No Acepta
26/10/2013	VV	0,90	0,00	No Acepta	0,84	0,00	No Acepta	0,92	0,00	No Acepta
	HH	0,85	0,00	No Acepta	0,93	0,00	No Acepta	0,94	0,00	No Acepta
05/11/2013	VV	0,88	0,00	No Acepta	0,92	0,00	No Acepta	0,92	0,00	No Acepta
	HH	0,85	0,00	No Acepta	0,80	0,00	No Acepta	0,91	0,00	No Acepta
22/11/2013	VV	0,86	0,00	No Acepta	0,87	0,00	No Acepta	0,85	0,00	No Acepta
	HH	0,82	0,00	No Acepta	0,87	0,00	No Acepta	0,85	0,00	No Acepta
01/12/2013	VV	0,86	0,00	No Acepta	0,93	0,00	No Acepta	0,91	0,00	No Acepta
	HH	0,91	0,00	No Acepta	0,90	0,00	No Acepta	0,92	0,00	No Acepta
17/12/2013	VV	0,91	0,00	No Acepta	0,90	0,00	No Acepta	0,89	0,00	No Acepta
	HH	0,90	0,00	No Acepta	0,84	0,00	No Acepta	0,88	0,00	No Acepta
14/01/2014	VV	0,89	0,00	No Acepta	0,91	0,00	No Acepta	0,87	0,00	No Acepta
	HH	0,92	0,00	No Acepta	0,91	0,00	No Acepta	0,90	0,00	No Acepta
30/01/2014	VV	0,89	0,00	No Acepta	0,92	0,00	No Acepta	0,91	0,00	No Acepta
	HH	0,90	0,00	No Acepta	0,90	0,00	No Acepta	0,94	0,00	No Acepta
23/02/2014	VV	0,92	0,00	No Acepta	0,89	0,00	No Acepta	0,92	0,00	No Acepta
	HH	0,91	0,00	No Acepta	0,94	0,00	No Acepta	0,94	0,00	No Acepta
25/02/2014	VV				0,94	0,00	No Acepta	0,93	0,00	No Acepta
	HH				0,92	0,00	No Acepta	0,92	0,00	No Acepta
23/03/2014	VV	0,85	0,00	No Acepta	0,91	0,00	No Acepta	0,89	0,00	No Acepta
	HH	0,89	0,00	No Acepta	0,93	0,00	No Acepta	0,85	0,00	No Acepta
06/04/2014	VV	0,11	0,00	No Acepta	0,89	0,00	No Acepta	0,92	0,00	No Acepta
	HH	0,09	0,00	No Acepta	0,93	0,00	No Acepta	0,86	0,00	No Acepta
14/04/2014	VV	0,89	0,00	No Acepta	0,89	0,00	No Acepta	0,86	0,00	No Acepta
	HH	0,89	0,00	No Acepta	0,82	0,00	No Acepta	0,93	0,00	No Acepta
22/04/2014	VV				0,86	0,00	No Acepta	0,87	0,00	No Acepta
	HH				0,87	0,00	No Acepta	0,84	0,00	No Acepta
22/05/2014	VV	0,83	0,00	No Acepta	0,88	0,00	No Acepta	0,88	0,00	No Acepta
	HH	0,78	0,00	No Acepta	0,88	0,00	No Acepta	0,92	0,00	No Acepta
24/05/2014	VV				0,89	0,00	No Acepta	0,92	0,00	No Acepta
	HH				0,90	0,00	No Acepta	0,91	0,00	No Acepta

ANEXO III

A continuación se presentan tablas con la proporción de píxeles clasificados en cada imagen óptica y las matrices de confusión de las mismas (ópticas y radar) y el código en R utilizado para la clasificación de imágenes SAR, COSMO SkyMed.

Imágenes ópticas

Tablas de proporción de píxeles clasificados en cada imagen.

Tabla 5.5: Proporción de píxeles clasificados para cada clase en imagen óptica.

Clasificación_181013 [7,406,352]	Clasificación_281213 [7,406,352]
Clase Píxeles Porcentaje	Clase Píxeles Porcentaje
Rastrojo Maíz [50742] 0.685%	Maíz [3694047] 49.877%
Rastrojo Soja [5636679] 76.106%	Soja [1886951] 25.477%
Suelo [738489] 9.971%	Sorgo [386495] 5.218%
Agua [114940] 1.552%	Suelo [1002148] 13.531%
Ciudad [156227] 2.109%	Agua [185386] 2.503%
Otros [709275] 9.577%	Ciudad [83488] 1.127%
	Otros [167837] 2.266%
Clasificación_301213 [7,406,352]	Clasificación_130114 [7,406,352]
Maíz [2248989] 30.366%	Maíz [2942916] 39.735%
Soja [1656416] 22.365%	Soja [3153176] 42.574%
Sorgo [430643] 5.815%	Sorgo [465972] 6.292%
Suelo [178521] 2.410%	Suelo [471341] 6.364%
Agua [2613949] 35.293%	Agua [196102] 2.648%
Ciudad [178398] 2.409%	Ciudad [73056] 0.986%
Otros [99436] 1.343%	Otros [103789] 1.401%
Clasificación_010314 [7,406,352]	Clasificación_120314 [7,406,352]
Maíz [1223281] 16.517%	Maíz [1317478] 17.788%
Soja [4036712] 54.503%	Soja [4600982] 62.122%
Sorgo [558675] 7.543%	Sorgo [515549] 6.961%
Suelo [184320] 2.489%	Suelo [202347] 2.732%
Agua [207929] 2.807%	Agua [105306] 1.422%
Ciudad [286017] 3.862%	Ciudad [196952] 2.659%
Otros [909418] 12.279%	Otros [467738] 6.315%
Clasificación_220314 [7,406,352]	Clasificación_190414 [7,406,352]
Maíz [1352448] 18.261%	Maíz [1462027] 19.740%
Soja [4758286] 64.246%	Soja [3834584] 51.774%
Sorgo [457931] 6.183%	Sorgo [701219] 9.468%
Suelo [171501] 2.316%	Suelo [595143] 8.036%
Agua [121591] 1.642%	Agua [71805] 0.970%
Ciudad [135802] 1.834%	Ciudad [449596] 6.070%
Otros [408793] 5.519%	Otros [291978] 3.942%

Confusión Matrix: SPOT 5 del 18/10/2013.

- Overall Accuracy = (38941/42346) 91,9591 %
- Kappa Coefficient = 0,8921

Class	Ground Truth (Percent)						Total
	CiudadTest	SueloTest	MaizTest	AguaTest	SojaTest	OtrosTest	
Unclassified	0,00	0,05	0,00	0,00	0,00	0,00	0,00
CiudadEntrenamiento	91,87	0,05	0,00	0,00	0,00	0,00	5,54
SueloEntrenamiento	0,71	97,02	98,62	0,00	0,00	0,00	35,35
MaizEntrenamiento	0,03	0,03	1,17	0,00	0,00	0,00	0,08
AguaEntrenamiento	1,85	0,00	0,00	89,86	0,00	0,28	8,86
SojaEntrenamiento	1,34	2,91	0,21	0,53	99,97	0,00	33,48
OtrosEntrenamiento	0,09	0,00	0,00	9,61	0,03	99,72	16,70
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
CiudadEntrenamiento	0,26	8,13
SueloEntrenamiento	15,91	2,98
MaizEntrenamiento	12,50	98,83
AguaEntrenamiento	0,48	10,14
SojaEntrenamiento	3,09	0,03
OtrosEntrenamiento	7,89	0,28

Confusion Matrix: Landsat 8 del 28/12/2013.

- Overall Accuracy = (47108/72313) 65,1446 %
- Kappa Coefficient = 0,5358

Class	Ground Truth (Percent)				CiudadTest	AguaTest	SueloTest	Total
	SorgoTest	MaizTest	SojaTest	OtrosTest				
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SorgoEntrenamiento	20,45	0,00	0,68	36,32	0,53	0,56	0,00	3,72
MaizEntrenamiento	7,14	87,10	36,51	4,52	1,19	2,40	4,58	38,34
SojaEntrenamiento	70,12	12,34	56,81	8,02	1,58	10,40	2,48	33,59
OtrosEntrenamiento	0,21	0,14	0,26	45,78	14,77	9,72	0,08	3,22
CiudadEntrenamiento	0,04	0,00	0,00	0,00	75,40	3,78	0,00	3,53
AguaEntrenamiento	2,05	0,00	0,00	0,08	4,12	65,38	0,00	6,68
SueloEntrenamiento	0,00	0,42	5,74	5,28	2,41	7,75	92,85	10,93
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SorgoEntrenamiento	40,80	79,55
MaizEntrenamiento	39,69	12,90
SojaEntrenamiento	36,81	43,19
OtrosEntrenamiento	53,40	54,22
CiudadEntrenamiento	10,42	24,60
AguaEntrenamiento	5,94	34,62
SueloEntrenamiento	29,98	7,15

Confusion Matrix: SPOT 5 del 30/12/2013.

- Overall Accuracy = (56946/75650) 75,2756 %
- Kappa Coefficient = 0,6564

Class	Ground Truth (Percent)							Total
	CiudadTest	SorgoTest	MaizTest	SojaTest	OtrosTest	SueloTest	AguaTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CiudadEntrenamiento	96,96	0,00	0,04	0,10	8,70	4,03	1,17	6,63
SorgoEntrenamiento	0,24	84,14	9,87	7,24	21,66	0,00	10,17	14,56
MaizEntrenamiento	0,00	0,16	67,06	3,98	2,03	0,22	14,48	19,78
SojaEntrenamiento	0,63	14,50	22,95	88,05	39,36	55,98	9,23	49,92
OtrosEntrenamiento	0,93	1,21	0,00	0,06	21,49	0,00	1,69	0,98
SueloEntrenamiento	0,67	0,00	0,03	0,43	0,00	39,78	0,08	3,37
AguaEntrenamiento	0,56	0,00	0,05	0,15	6,76	0,00	63,18	4,76
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
CiudadEntrenamiento	10,89	3,04
SorgoEntrenamiento	47,42	15,86
MaizEntrenamiento	13,96	32,94
SojaEntrenamiento	26,99	11,95
OtrosEntrenamiento	31,59	78,51
SueloEntrenamiento	6,95	60,22
AguaEntrenamiento	6,72	36,82

Confusion Matrix: Landsat 8 del 13/01/2014.

- Overall Accuracy = (56412/75490) 74,7278 %
- Kappa Coefficient = 0,6557

Class	Ground Truth (Percent)							Total
	SojaTest	OtrosTest	AguaTest	SorgoTest	MaizTest	CiudadTest	SueloTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	80,64	13,26	6,26	2,88	29,02	1,75	0,00	42,16
OtrosEntrenamiento	0,00	0,00	1,84	0,00	4,67	0,00	0,00	1,36
AguaEntrenamiento	0,04	0,93	89,70	0,90	0,03	5,90	0,42	8,73
SorgoEntrenamiento	2,28	55,11	0,13	89,63	0,01	4,75	0,00	11,05
MaizEntrenamiento	17,05	30,57	2,04	6,59	65,29	8,64	4,24	26,09
CiudadEntrenamiento	0,00	0,13	0,03	0,00	0,02	78,01	28,44	5,28
SueloEntrenamiento	0,00	0,00	0,00	0,00	0,97	0,96	66,89	5,32
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	20,66	19,36
OtrosEntrenamiento	100,00	100,00
AguaEntrenamiento	4,60	10,30
SorgoEntrenamiento	26,05	10,37
MaizEntrenamiento	36,37	34,71
CiudadEntrenamiento	40,69	21,99
SueloEntrenamiento	5,36	33,11

Confusion Matrix: SPOT 5 del 01/03/2014.

- Overall Accuracy = (62866/75783) 82,9553 %
- Kappa Coefficient = 0,7683

Class	Ground Truth (Percent)							Total
	SojaTest	OtrosTest	AguaTest	SorgoTest	MaizTest	CiudadTest	SueloTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	92,51	15,24	0,00	15,16	18,40	0,00	0,00	44,74
OtrosEntrenamiento	1,26	28,38	0,02	8,66	1,96	2,06	13,77	3,93
AguaEntrenamiento	0,00	0,00	93,87	0,10	0,00	0,43	0,07	6,63
SorgoEntrenamiento	2,41	32,18	4,80	69,76	1,05	0,09	0,30	8,97
MaizEntrenamiento	3,00	18,16	1,13	1,99	78,52	0,00	0,00	21,95
CiudadEntrenamiento	0,28	0,80	0,15	2,90	0,07	81,40	10,26	6,21
SueloEntrenamiento	0,54	5,24	0,04	1,42	0,00	16,02	75,60	7,57
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	14,56	7,49
OtrosEntrenamiento	77,41	71,62
AguaEntrenamiento	0,62	6,13
SorgoEntrenamiento	29,36	30,24
MaizEntrenamiento	9,42	21,48
CiudadEntrenamiento	20,26	18,60
SueloEntrenamiento	19,72	24,40

Confusion Matrix: SPOT 5 del 12/03/2014.

- Overall Accuracy = (57403/76343) 75,1909 %
- Kappa Coefficient = 0,6645

Class	Ground Truth (Percent)							Total
	CiudadTest	SojaTest	OtrosTest	SorgoTest	MaizTest	SueloTest	AguaTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CiudadEntrenamiento	92,84	0,20	0,00	1,31	0,01	26,66	0,00	8,13
SojaEntrenamiento	0,07	86,32	20,78	55,29	11,13	6,37	0,11	44,41
OtrosEntrenamiento	0,00	1,20	44,26	0,35	9,03	0,00	0,00	4,17
SorgoEntrenamiento	0,09	8,49	5,45	40,84	7,26	0,42	3,12	9,42
MaizEntrenamiento	0,00	3,06	21,88	2,03	72,53	0,00	14,89	21,39
SueloEntrenamiento	6,90	0,72	7,64	0,06	0,04	59,45	0,00	6,15
AguaEntrenamiento	0,11	0,00	0,00	0,12	0,00	7,10	81,87	6,34
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
CiudadEntrenamiento	31,07	7,16
SojaEntrenamiento	20,26	13,68
OtrosEntrenamiento	67,04	55,74
SorgoEntrenamiento	60,90	59,16
MaizEntrenamiento	14,75	27,47
SueloEntrenamiento	15,73	40,55
AguaEntrenamiento	10,02	18,13

Confusion Matrix: SPOT 5 del 22/03/2014.

- Overall Accuracy = (55846/76343) 73,1514 %
- Kappa Coefficient = 0,6209

Class	Ground Truth (Percent)							Total
	SojaTest	OtrosTest	SorgoTest	MaizTest	SueloTest	AguaTest	CiudadTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	92,62	35,68	80,71	18,80	28,54	0,28	1,15	53,68
OtrosEntrenamiento	0,14	36,87	0,65	0,88	0,17	0,24	0,02	1,51
SorgoEntrenamiento	1,81	7,60	14,15	9,90	0,05	1,45	0,00	4,85
MaizEntrenamiento	3,17	17,27	2,59	70,42	1,29	16,77	0,00	21,06
SueloEntrenamiento	2,23	2,58	0,00	0,00	53,99	0,00	21,51	7,00
AguaEntrenamiento	0,00	0,00	0,26	0,00	4,15	81,25	0,00	6,05
CiudadEntrenamiento	0,02	0,00	1,64	0,01	11,82	0,00	77,32	5,86
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	29,22	7,38
OtrosEntrenamiento	24,48	63,13
SorgoEntrenamiento	73,68	85,85
MaizEntrenamiento	15,92	29,58
SueloEntrenamiento	32,78	46,01
AguaEntrenamiento	6,37	18,75
CiudadEntrenamiento	20,29	22,68

Confusion Matrix: Landsat 8 del 19/04/2014.

- Overall Accuracy = (63808/78113) 81,6868 %
- Kappa Coefficient = 0,7536

Class	Ground Truth (Percent)							Total
	SojaTest	OtrosTest	AguaTest	SorgoTest	MaizTest	Suelo_trata	CiudadTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	86,16	44,81	3,32	18,68	22,12	0,16	0,00	43,31
OtrosEntrenamiento	0,47	27,36	0,00	1,03	0,10	0,05	0,00	1,14
AguaEntrenamiento	0,00	0,00	77,27	0,51	0,00	0,00	0,00	7,32
SorgoEntrenamiento	2,53	13,60	0,41	72,43	0,79	0,00	0,00	8,04
MaizEntrenamiento	3,50	4,90	19,00	6,94	76,51	0,00	0,00	22,76
SueloEntrenamiento	6,94	3,08	0,00	0,00	0,15	98,21	1,28	11,01
CiudadEntrenamiento	0,39	6,25	0,00	0,41	0,33	1,58	98,72	6,42
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	20,24	13,84
OtrosEntrenamiento	27,19	72,64
AguaEntrenamiento	0,61	22,73
SorgoEntrenamiento	20,63	27,57
MaizEntrenamiento	17,38	23,49
SueloEntrenamiento	27,12	1,79
CiudadEntrenamiento	9,24	1,28

Imágenes radar

Confusion Matrix: Clasificación temporal de 6 imágenes radar sin tener en cuenta dirección de enfoque, órbita y ángulo.

- Overall Accuracy = $(11292/27399)$ 41,2132 %
- Kappa Coefficient = 0,2948

Class	Ground Truth (Percent)							Total
	SojaTest	MaizTest	OtrosTest	SueloTest	AguaTest	CiudadTest	SorgoTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	42,82	3,63	12,67	1,13	1,39	2,28	31,18	12,46
MaizEntrenamiento	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
OtrosEntrenamiento	6,85	2,78	19,81	19,98	15,57	8,85	1,56	12,39
SueloEntrenamiento	9,76	34,40	39,06	50,76	29,03	18,12	3,16	27,42
AguaEntrenamiento	0,65	5,88	6,21	6,12	43,27	14,37	1,00	13,26
CiudadEntrenamiento	0,00	0,00	0,00	0,00	0,06	26,91	0,00	4,54
SorgoEntrenamiento	39,92	53,31	22,26	22,01	10,68	29,47	63,09	29,94
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	48,17	57,18
MaizEntrenamiento	0,00	100,00
OtrosEntrenamiento	86,19	80,19
SueloEntrenamiento	55,06	49,24
AguaEntrenamiento	36,66	56,73
CiudadEntrenamiento	0,24	73,09
SorgoEntrenamiento	73,95	36,91

Confusion Matrix: Clasificación temporal de 5 imágenes radar con igual dirección de enfoque, órbita y ángulo.

- Overall Accuracy = $(11890/27399)$ 43,3957
- Kappa Coefficient = 0,3204

Class	Ground Truth (Percent)							Total
	SojaTest	MaizTest	OtrosTest	SueloTest	AguaTest	CiudadTest	SorgoTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	78,58	14,53	33,66	14,85	5,74	1,74	47,68	26,16
MaizEntrenamiento	0,48	3,10	0,38	0,03	0,04	0,02	0,77	0,32
OtrosEntrenamiento	0,73	0,53	15,12	16,81	6,04	5,32	0,2	7,61
SueloEntrenamiento	5,23	35,79	22,72	25,85	35,30	3,19	0,44	17,69
AguaEntrenamiento	2,01	10,04	14,82	19,38	39,36	13,04	0,44	16,52
CiudadEntrenamiento	1,67	1,28	3,76	6,01	4,53	65,91	8,89	15,14
SorgoEntrenamiento	11,30	34,72	9,54	17,07	9,01	10,79	41,5	16,56
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	54,71	21,42
MaizEntrenamiento	67,42	96,90
OtrosEntrenamiento	82,82	84,88
SueloEntrenamiento	64,53	74,15
AguaEntrenamiento	53,76	60,64
CiudadEntrenamiento	26,80	34,09
SorgoEntrenamiento	68,97	58,43

Confusion Matrix: Todas las imágenes COSMO SkyMed en ambas polarizaciones y bandas roja e infrarroja de una imagen SPOT 5.

- Overall Accuracy = (17757/27399) 64,8089
- Kappa Coefficient = 0,5792

Class	Ground Truth (Percent)							Total
	SojaTest	MaizTest	OtrosTest	SueloTest	AguaTest	CiudadTest	SorgoTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	83,61	13,57	46,24	1,25	0,00	0,24	52,1	23,85
MaizEntrenamiento	1,14	44,23	1,22	0,95	1,03	0,11	2,33	2,53
OtrosEntrenamiento	4,87	10,58	23,69	9,46	2,18	0,35	0,92	6,03
SueloEntrenamiento	0,82	5,88	4,10	39,84	0,41	7,25	0,24	11,68
AguaEntrenamiento	0,51	5,45	21,62	1,20	94,28	0,26	0,24	20,80
CiudadEntrenamiento	0,00	0,00	0,46	24,78	0,13	91,17	0,94	21,53
SorgoEntrenamiento	9,05	20,30	2,66	22,52	1,96	0,63	43,19	13,58
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	47,15	16,39
MaizEntrenamiento	40,17	55,77
OtrosEntrenamiento	66,06	76,31
SueloEntrenamiento	17,19	60,16
AguaEntrenamiento	12,00	5,72
CiudadEntrenamiento	28,78	8,83
SorgoEntrenamiento	60,68	56,81

Confusion Matrix: Todas las imágenes COSMO SkyMed en polarización VV y bandas roja e infrarroja de una imagen SPOT 5.

- Overall Accuracy = (15923/27399) 58,1153
- Kappa Coefficient = 0,5002

Class	Ground Truth (Percent)							Total
	SojaTest	MaizTest	OtrosTest	SueloTest	AguaTest	CiudadTest	SorgoTest	
Unclassified	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SojaEntrenamiento	79,67	17,41	46,24	0,33	0,06	0,00	39,74	21,61
MaizEntrenamiento	0,02	0,43	0,00	0,00	0,04	0,00	0,09	0,04
OtrosEntrenamiento	8,57	48,61	23,23	8,42	6,77	0,04	3,40	8,74
SueloEntrenamiento	0,00	0,00	1,01	21,24	0,38	8,33	0,15	6,74
AguaEntrenamiento	0,05	2,03	18,37	0,00	88,17	0,00	0,00	18,78
CiudadEntrenamiento	0,05	0,21	5,95	65,42	0,02	91,60	4,81	32,41
SorgoEntrenamiento	11,64	31,30	5,19	4,59	4,57	0,02	51,82	11,68
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00

Class	Commission (Percent)	Omission (Percent)
SojaEntrenamiento	44,41	20,33
MaizEntrenamiento	60,00	99,57
OtrosEntrenamiento	77,05	76,77
SueloEntrenamiento	23,46	78,76
AguaEntrenamiento	8,86	11,83
CiudadEntrenamiento	52,47	8,40
SorgoEntrenamiento	45,17	48,18

Código R de redes neuronales

Librerías necesarias para correr el algoritmo:

- library('splus2R')
- library('rasclass')
- library('rgdal')
- library('sp')
- library('raster')

```

1 #Rois de entrenamiento de cultivo maiz, soja y sorgo, suelo, agua, ciudad y otros.
2 dimensions <- dim(ROis_cultivos)
3 entrena <- as.numeric(ROis_cultivos)
4 entrena[which(entrena == 0)] <- NA
5
6 #Bandas VV de imagenes COSMO SkyMed
7 var1 <- as.numeric(V_171213)
8 var2 <- as.numeric(V_140114)
9 var3 <- as.numeric(V_300114)
10 var4 <- as.numeric(V_230314)
11 var5 <- as.numeric(V_220514)
12
13 datos <- data.frame(entrena, var1, var2, var3, var4, var5)
14
15 oobject <- new("rasclass")
16 object <- setRasclassData(datos, ncols = dimension[1],
17                           nrows = dimension[2], xllcorner = 0, yllcorner = 0,
18                           cellsize = 1, NAvalue = -9999, samplename = "entrena")
19
20 outlist <- list()
21 outlist[["logit"]] <-
22   classifyRasclass(object, method = "logit")
23 summary(outlist[["logit"]])
24 outlist[["neuralNetwork"]] <-
25   classifyRasclass(object, method = "neuralNetwork")
26 summary(outlist[["neuralNetwork"]])
27 for(i in 1:length(outlist)) {
28   image(outlist[[i]]@predicted)
29
30   opar <- par(mfrow = c(2, 2))Grid)
31   title(names(outlist)[[i]])
32 }
33
34 par(opar)
35 matrizdeGrid <- matrix(outlist[[1]]@predictedGrid@grid,
36                       nrow=dimension[1], ncol=dimension[2])
37 x <- raster(matrizdeGrid)
38 if (require(rgdal)) {
39   r <- writeRaster(x, filename="logit.tif",
40                   format="GTiff", overwrite=TRUE)
41 }
42
43 matrizdeGrid2 <- matrix(outlist[[2]]@predictedGrid@grid,
44                       nrow=dimension[1], ncol=dimension[2])
45 x2 <- raster(matrizdeGrid2)
46 if (require(rgdal)) {
47   r <- writeRaster(x2, filename="Clasificacion.tif",
48                   format="GTiff", overwrite=TRUE)

```

Bibliografía

- [1] M. Di Pace, “Las utopías del medio ambiente. desarrollo sustentable en la argentina,” *Bibliotecas Universitarias. Centro Editor de America latina*, 1992.
- [2] E. Viglizzo, “Cómo mejorar la producción de alimentos con los recursos naturales del país.,” *Premio FAIGA*, p. 75, 1986.
- [3] U. Martínez Ortiz, *Producción agropecuaria y medio ambiente: Propuestas compartidas para su sustentabilidad*. 2007.
- [4] J. C. Montoya, F. J. Babinec, N. M. Rodríguez, J. Pérez Fernández, and A. A. Bono, “Uso de agroquímicos en la provincia de la pampa.,” *Boletín de divulgación técnica N° 66. INTA.*, 1999.
- [5] E. Viglizzo, *La Trampa de Malthus. Agricultura, competitividad y Medio Ambiente en el siglo XXI*. 2001.
- [6] C. Bagnato, C. Conde, Y. Noe, C. C., S. Baeza, H. Paoli, M. Vallejos, F. Gallego, L. Vale, L. Amdan, H. Elena, M. Texeira, J. Mosciaro, L. Ciuffoli, C. Morales, P. Baldasini, S. Aguiar, M. Arocena, J. Volante, and P. J.M., “Utilización de firmas espectrales de alta resolución temporal para la elaboración de mapas de uso agrícola y estimaciones de superficie cultivada a escala de lote en argentina y uruguay,” <http://www.inta.gob.ar/documentos>, 2012.
- [7] Y. Ding and Z. Chen, “Review of crop identification and area monitoring based on sar images,” *National high technology research and development program of China*, 2010.
- [8] A. M. Hernández, A. Gagliardini, and J. A. Moragues, “Uso de la información espacial en el área económica y productiva: sectores agropecuarios, pesqueros y forestales,” *Comisión Nacional de Actividades Espaciales (CONAE)*, 2002.
- [9] M. Altieri and C. I. Nicholls, “Agroecología: Única esperanza para la soberanía alimentaria y la resiliencia socioecológica,” *Agroecología*, vol. 2, p. 65:83, 2012.
- [10] E. Chuvieco, *Fundamentos de Teledetección Espacial*. 3° ed., 1996.
- [11] D. Lu and Q. Weng, “A survey of image classification methods and techniques for improving classification performance,” *International Journal of Remote Sensing*, vol. 28, no. 5, p. 823:870, 2007.
- [12] E. Chuvieco, *Teledetección Ambiental. La observación de la Tierra desde el espacio*. 2° ed., 2006.
- [13] M. Claverol, *Compendio de teledetección geológica*. Compendio de teledetección geológica, Universidad de Oviedo, Servicio de Publicaciones, 1993.

- [14] H. Mehl and O. Peinado, “Fundamentos del procesamiento digital de imágenes,” *Aplicación de la teledetección y de los sistemas de información geográfica en la gestión de recursos naturales. Parte I: Fundamentos teóricos y prácticos.*, 1997.
- [15] E. Méndez, A. Cabello, J. Frieyro, A. Hayas, L. Granado, G. Montoya, I. Pino, and J. Domínguez, “Desarrollo de una metodología para la caracterización de praderas de fanerógamas marinas en el litoral andaluz mediante técnicas de teledetección con sensores hiperespectrales,” *Asociación Española de Teledetección Revista de Teledetección*, 2011.
- [16] C. García, J. Guevara, Y. Rogel, and S. d. I. G. y. T. Asociación de Geógrafos Españoles. Grupo de Métodos Cuantitativos, *Medio ambiente, recursos y riesgos naturales: análisis mediante tecnología SIG y teledetección*. Medio ambiente, recursos y riesgos naturales, análisis mediante tecnología SIG y teledetección, Universidad de Murcia, 2004.
- [17] R. Myneni, S. Hoffman, Y. Knyazikhin, J. Privette, J. Glassy, Y. Tian, Y. Wang, X. Song, Y. Zhang, G. Smith, A. Lotsch, A. Fried, J. Morisette, P. Votava, R. Nemani, and S. Running, “Global products of vegetation leaf area and fraction absorbed par from year one of modis data.,” *Remote Sensing of Environment*, no. 83, pp. 214–231, 2002.
- [18] A. Gitelson, A. Viña, V. Ciganda, and T. Rundquist, D.C.and Arkebauer, “Remote estimation of canopy chlorophyll content in crops.,” *Geophysical Reserch Letters*, vol. 32, 2005.
- [19] M. Bocco, G. Ovando, S. Sayago, and E. Willington, “Modelos simples para estimar cobertura de suelo agrícola a partir de imágenes modis: aplicación a la zona central de córdoba (argentina).,” *Congreso Argentino de AgroInformatica, CAI.*, p. 61, 2013.
- [20] A. Richardson and C. Wiegand, “Distinguishing vegetation from soil background information.,” *Photogrammetric Engineering and Remote Sensing.*, 1977.
- [21] M. Bocco, G. Ovando, S. Sayago, E. Willington, and S. Heredia, “Estimating soybean ground cover from satellite images using neural-networks models,” *International Journal of Remote Sensing*, vol. 33, no. 6, p. 1717:1728, 2011.
- [22] A. Larrañaga, L. Albizua, and J. Avarez-Mozos, “Clasificación de cultivos en la zona media de navarra mediante imágenes radar polarimétricas,” *Revista Teledetección*, no. 34, p. 77:78, 2010.
- [23] G. Pajares, C. López-Martínez, F. J. Sánchez-Lladó, and I. Molina, “Improving wishart syntetic aperture radar image classification based on hopfield neural network,” *Remote Sensing*, no. 4, p. 3571:3595, 2012.
- [24] E. Willington, M. Nolasco, and M. Bocco, “Clasificación supervisada de suelos de uso agrícola en la zona central de córdoba (argentina): comparación de distintos algoritmos sobre imágenes landsat,” *Congreso Argentino de AgroInformatica*, vol. 42, 2013.
- [25] H. McNairn, J. J. Van der Sanden, R. J. Brown, and J. Ellis, “The potencial of radarsat-2 for crop mapping anda assessing crop condition,” *Second International Conference on Geospatial Information in Agriculture and Forestry, Lake Buena Vista, Florida*, p. 10:12, 2000.
- [26] Y. Wu, M. Li, P. Zhang, H. Zong, P. Xiao, and C. Liu, “Unsupervised multi-class segmentation of sar images using triplet markov based on edge penalty,” *Pattern Recognition Letters*, p. 1532:1540, 2011.

- [27] M. Bocco, G. Ovando, S. Sayago, and E. Willington, "Neural network models for land cover classification from satellite images. modelos de redes neuronales para la clasificación de cobertura del suelo a partir de imágenes satelitales," *Agricultura Técnica - Chile*, vol. 67, no. 4, p. 414:421, 2007.
- [28] J. Hilera and V. Martínez, *Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones*. alfaomega ra-ma ed., 2000.
- [29] J. P. Argañaraz and E. I., "Análisis comparativo entre las máquinas de vectores soporte y el clasificador de máxima probabilidad para la discriminación de cubiertas de suelos," *Revista de Teledetección*, no. 36, 2011.
- [30] I. Castillejo González and F. López Granados, "Object and pixel-based classification for mapping crops and their agri-environmental associated measures in quickbird images.," *Computers and Electronics in Agriculture*, vol. 68, pp. 207–215, 2009.
- [31] B. Aiazia, L. Alparone, S. Baronti, A. Garzelli, and F. Nencini, "Information-theoretic multitemporal features for change analysis from sar images," *Image and Signal Processing for Remote Sensing XIV*, 2008.
- [32] M. Bocco, G. Ovando, S. Sayago, E. Willington, and S. Heredia, "Estimating soybean ground cover from satellite images using neural-networks models.," *International Journal of Remote Sensing*, vol. 33, no. 6, pp. 1717–1728, 2012.
- [33] J. Guerschman, J. Paruelo, C. Di Bella, M. Giallorenzi, and F. Pacin, "Land cover classification in the argentine pampas using multi-temporal landsat tm data.," *Remote Sensing*, no. 24, pp. 3381–3402, 2003.
- [34] G. Sandoval, R. Vazquez, P. Garcia, and J. Ambrosio, "Crop classification using different color spaces and rbf neural networks.," *Artificial Intelligence and Soft Computing Lecture Notes in Computer Science Volume.*, 2014.
- [35] B. Wardlow, S. Egbert, and J. Kastens, "Analysis of time-series modis 250 m vegetation index data for crop classification in the u.s. central great plains.," *Remote Sensing of Environment*, no. 3, pp. 290–310, 2007.
- [36] J. Martínez-Casasnovas and B. X. A., "Viticultura de precisión: Predicción de cosecha a partir de variables del cultivo e índices de vegetación.," *Asociación Española de Teledetección.*, pp. 33–36, 2005.
- [37] J. R. Jensen, "Remote sensing of the environment: an earth resource perspective.," *Prentice Hall*, 2000.
- [38] S. Lanfri, "Desarrollo de una metodología para la detección de cuerpos de agua mediante el análisis de imágenes sar cosmo skymed y de dems," Master's thesis, Universidad Nacional de Córdoba, 2011.
- [39] K. Chen, W. Huang, D. Tsay, and F. Amar, "Classification of multifrequency polarimetric sar imagery using a dynamic learning neural network.," *IEEE Transactions on Geoscience and Remote Sensing.*, 1996.
- [40] F. Capodici, G. D'Urso, and A. Maltese, "Investigating the relationship between x-band sar data from cosmo-skymed satellite and ndvi for lai detection.," *Remote Sensing*, 2013.

- [41] X. Wang, L. Ge, and X. Li, "Pasture monitoring using sar with cosmo-skymed, envisat asar, and alos palsar in otway, australia," *Remote Sensing*, vol. 5, 2013.
- [42] N. Kussul, S. Skakun, A. Shelestov, and O. Kussul, "The use of satellite sar imagery to crop classification in ukraine within jecam project.," *Geoscience and Remote Sensing Symposium (IGARSS)*, 2014.
- [43] F. Soria, C. Fandos, R. Kasianuk, P. Scandalariis, and J. Carreras Baldrés, "Análisis multitemporal de imágenes sar cosmo-skymed (csk) para identificar la respuesta espectral del cultivo de caña de azúcar durante el periodo de cosecha, en la provincia de tucumán, república argentina.," *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, 2013.
- [44] A. C. A. e Instituto Nacional de Tecnología Agropecuaria., *Los suelos*. Gobierno de la Provincia de Córdoba, 2006.
- [45] F. Piatti and L. Ferreyra, "Evaluación de cultivares comerciales de soja. campaña 2008/09.," *Cartilla Digital Manfredi-INTA EEA Manfredi*, vol. 5, p. 1:20, 2009.
- [46] F. Piatti and L. Ferreyra, "Ensayos comparativos de rendimiento de maíz: Red interna de inta manfredi, campaña 2007-08," *Cartilla Digital Manfredi-INTA EEA Manfredi*, vol. 4, p. 1:11, 2008.
- [47] MAGyP., "Producción, área sembrada y cosechada, cotizaciones nacionales e internacionales," 2013.
- [48] C. Daza and C. Sánchez, "Zonas agoeconómicas homogéneas. córdoba: Estudios socioeconómicos de los sistemas de producción y recursos naturales," *Buenos Aires: Ediciones del Instituto Nacional de Tecnología Agropecuaria. ISSN*, vol. 10, p. 1851:6955, 2009.
- [49] S. de Menería de la Nación., "Geología de la provincia de córdoba." <http://www.mineria.gov.ar/estudios/irn>.
- [50] S. S. S. U. S. D. of Agriculture Natural Resources Conservation Service, *Soil Taxonomy. A Basic System of Soil Classification for Making and Interpreting Soil Surveys*. 1999.
- [51] D. Sbarato, J. Ortega, and V. Sbarato, *Planificación y gestión de los estudios de impacto ambiental/ Planning and management of environmental impact studies*. Salud Ambiental/ Environmental Health, German Marcelo Ferrero, 2007.
- [52] A. C. A. S.E. and I. N. de Tecnología Agropecuaria EEA Manfredi., "Los suelos," tech. rep., 2003.
- [53] A. López, *Manual de Edafología*. Departamento de Cristalografía, Mineralogía y Química. Agrícola de la Universidad de Sevilla, 2005.
- [54] V. Nakama and R. Sobral, "Índices de productividad. método paramétrico de evaluación de tierras.," *Secretaría de Agricultura, Ganadería y Pesca- INTA. Documento del Proyecto PNUD Arg. 85/019, Buenos Aires*, 1987.
- [55] N. Barbieris and R. Bongiovanni, "Informe económico para el productor ii: Departamento río segundo, córdoba incorporando balance de nutrientes.," tech. rep., Insituto Nacional de Tecnología Agropecuaria, 2014.

- [56] E. Severina, “Plan tecnológico regional 2009-2011 inta centro regional córdoba.”
- [57] C. Ghida Gaza, “Resultados económicos esperados para la campaña de soja 2014/15.” <http://www.inta.gob.ar/documentos/resultados-economicos-esperados-para-la-campana-de-soja-2014-15>.
- [58] D. G. de Estadística y Censo de Córdoba, “Encuesta nacional agropecuaria.” <http://www.estadistica.cba.gov.ar/Economia/SectorPrimario/CensoNacionalAgropecuario2008>, 2008.
- [59] C. Gutiérrez and L. Nieto, *Teledetección: Nociones y Aplicaciones*. Carlos Pérez Gutiérrez, Éngel Luis Muñoz Nieto, 2006.
- [60] V. Olaya, *Sistema de Informacion geografica*. 2011.
- [61] C. N. de Estudios Espaciales Frances, “Satellite pour l’observation de la terre.” <http://www.cnes.fr>.
- [62] U. S. G. Survey., “Librería espectral.” <http://www.speclab.cr.usgs.gov/spectral-lib>.
- [63] A. Ariza, “Descripción y corrección de productos landsat 8. ldm.” tech. rep., Insituto GEOgráfico Agustín Codazzi. Centro de Investigación y Desarrollo - CIAF., 2013.
- [64] U. S. G. Survey., “Landsat data comunity mission.” <http://www.un-spider.org/sites/default/files/LDCM-L8.R1.pdf>, 2013.
- [65] J. Van Zyl and Y. Kim, “Synthetic aperture radar polarimetry.” *JPL Space Science and Technology*, 2010.
- [66] S. Liang, *Quantitative Remote Sensing of Land Surface*. 2004.
- [67] A. S. Italiana., “Cosmo skymed.” www.e-geos.it.
- [68] A. S. Italiana., “Cosmo skymed sar products handbook.” <http://www.cosmo-skymed.it/docs/ASI-CSM-ENG-RS-092-A-CSKSARProductsHandBook.pdf>, 2007.
- [69] C. N. de Actividades Espaciales., “Saocom.” <http://www.conae.gov.ar/satelites/saocom.html>.
- [70] N. Aeronautics and S. Administration., “Misión topográfica de radar shuttle.” <http://www.srtm.csi.cgiar.org>.
- [71] T. Farr, “The shuttle radar topography mission,” *Geophys*, 2007.
- [72] W. Fehr and C. Caviness, “Stages of soybean development.” *Iowa State University Special Report*, no. 80, p. 11, 1977.
- [73] S. Ritchie and J. Hanway, “How a corn plant develops.” *Iowa State University Technology Special Report*, p. 48, 1982.
- [74] T. Bense, “Educación en percepción remota en el Ámbito del mercosur.” <http://www.selper.org.uy>, 2007.

- [75] A. Brizuela, C. Aguirre, and I. Velasco, “Aplicación de métodos de corrección atmosférica de datos landsat 5 para análisis multitemporal,” 2007.
- [76] S. S. Hantson, E. Chuvieco, X. Pons, C. Domingo, C. and Cea, G. Moré, J. Cristobal, P. J.J., and J. Tejeiro, “Cadena de pre-procesamiento estándar para las imágenes landsat del plan nacional de teledetección.,” *Asociación Española de Teledetección Revista de Teledetección*, no. 36, 2011.
- [77] S. Gandía, “La teledetección en el seguimiento de las áreas cultivadas. en: La teledetección en el seguimiento de los fenómenos naturales. recursos renovables. agricultura.,” *Universitat de València. Estudio General. Unidad de Teledetección. Departament de Termodinámica.*, 1991.
- [78] G. Chander, X. Xiong, T. Choi, and G. Angal, “Monitoring on-orbit calibration stability of terra modis and landsat 7 etm+ sensors using pseudo-invariant test sites.,” *Remote Sensing of Environment.*, vol. 114, pp. 925–939, 2010.
- [79] C. Song, C. Woodcock, K. Seto, M. Lenney, and S. Macomber, “Classification and change detection using landsat tm data: When and how to correct atmospheric effects?,” *Remote Sensing of Environment*, no. 75, pp. 230–244, 2001.
- [80] E. S. Agency, *Next ESA SAR Toolbox (NEST)*.
- [81] J. Lee, “Refined filtering of image noise using local statistics.,” *Computer Graphics and Image Processing*, vol. 15, pp. 380–389, 1981.
- [82] R Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2013.
- [83] J. Devore, *Probabilidad y estadística para ingeniería y ciencias*. 6° ed., 2007.
- [84] M. Picco, G. Palacio, E. Moschetti, and A. Frery, “Evaluación de filtros map para nuevos modelos de imágenes sar,” *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto*, 2007.
- [85] G. Gao, “Statistical modeling of sar images: A survey,” *Sensors*, vol. 10, pp. 775–795, 2010.
- [86] J. Miralles, *La teledetección en el seguimiento de los fenómenos naturales. Recursos renovables: agricultura*. Universitat, Unidad de Teledetección, Departament de Termodinámica, 1991.
- [87] J. Sobrino, *Teledetección*. Universidad de València. Servicio de Publicaciones., 2001.
- [88] M. Bocco, S. Sayago, and E. Willington, “Neural network and crop residue index multiband models for estimating crop residue cover from landsat tm and etm+ images,” *International Journal of Remote Sensing*, vol. 35, no. 10, pp. 3651–3663, 2014.
- [89] J. Zurada, *Intgroduction to artificial neural systems*. West Publishing Company, 1992.
- [90] L. Llano, A. Hoyos, F. Arias, and J. Velásquez, “Comparison of the activation functions performance in neural networks feedforward to approximate data functions with and without noise.,” *Revista Avances en Sistemas e Informática.*, 2007.
- [91] R. López and J. Fernández, *Las Redes Neuronales Artificiales*. Metodología y Análisis de Datos en Ciencias Sociales, Netbiblo, 2008.

- [92] F. Izaurieta and C. Saavedra, “Redes neuronales artificiales,” *Revista Charlas de Física*, vol. 16, p. 01:15, 1999.
- [93] J. Landis and G. Koch, “The measurement of observer agreement for categorical data.,” *Biometrics*, vol. 33, pp. 159–74, 1977.
- [94] J. Richards and X. Jia, *Remote Sensing Digital Image Analysis. An Introduction*. 2006.
- [95] J. Richards, *Remote Sensing with Imaging Radar*. 2009.
- [96] H. Mott, *Remote sensing with polarimetric radar*. 2007.
- [97] O. H. Bustos, M. M. Lucini, and F. A. C., ““m-estimators of roughness and scale for 0 gamma modelled sar imagery”,” *Applied Signal Processing*, no. 1, pp. 105–114, 2002.
- [98] A. Frery, M. Abraao, D. C. Nascimento, and R. Cintra, “Analytic expressions for stochastic distances between relaxed complex wishart distributions,” *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, 2013.
- [99] S. Lanfri, G. Palacio, M. Lanfri, M. Scavuzzo, and A. Frery, “Information content in cosmo skymed data.,” *Geoscience and Remote Sensing Symposium (IGARSS), IEEE International*, 2013.
- [100] L. Torres, T. Cavalcante, and A. Frery, *Speckle reduction using stochastic distances.*, vol. 7441. CIARP 2012 – Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications, L. Alvarez, M. Mejail, L. Gomez, and J. Jacobo, lecture notes in computer science ed., 2012.
- [101] A. Frery, A. Nascimento, and R. Cintra, “Information theory and image understanding: An application to polarimetric sar imagery,” *Chilean Journal of Statistics*, 2011.
- [102] F. Ulaby, R. Moore, and A. Fung, “Microwave remote sensing, active and passive,” *From Theory to Applications, Artech House, Massachusettes.*, vol. 3, 1986.
- [103] J. Casseti, J. Gambini, and A. Frery, “Estimación de parámetros utilizando distancias estocásticas para datos con ruido speckle.,” *14th Argentine Symposium on Technology, AST.*, 2013.
- [104] A. Nacimiento, C. Cintra, and A. Frery, “Hypothesis testing in speckled data with stochastic distances,” *IEEE Transactions on Geoscience and Remote Sensing*, pp. 373–385, 2010.
- [105] E. Suarez, *Significado de los intervalos de confianza para los estudiantes de ingeniería en México*. PhD thesis, Universidad de Granada, 2008.
- [106] C. Manjarrez Domínguez, C. Pinedo Álvarez, C. Vélez Sánchez Verín, and A. Pinedo Álvarez, “Separabilidad espectral de cultivos agrícolas con imágenes landsat tm,” *Tecnociencia Chihuahua*, vol. 1, no. 2, 2007.
- [107] M. Martín and E. Chuvieco, “Propuesta de un nuevo índice para cartografía de áreas quemadas: aplicación a imágenes noaaavhrr y landsat-tm,” *Revista de Teledetección*, no. 16, pp. 57–64, 2001.
- [108] P. Thenkabail, J. Lyon, and A. Huete, *Hyperspectral Remote Sensing of Vegetation*. CRC Press, 2011.

- [109] L. W. Med., “Librería espectral..” <http://www.landwatermed.net/cameleo/uk/res-medspec>,.
- [110] R. U. Universidad de Southampton, “Librería espectral..” <http://www.soton.ac.uk/epfs/resources/speclibrary>,.
- [111] E. U. Universidad de Kentucky, “Librería espectral..” <http://www.murraystate.edu/qacd/cos/marc/projects/nasa98/veg-library>.
- [112] N. Aeronautics and S. Administration., “Librería espectral..” <http://www.speclab.cr.usgs.gov/spectral-lib>.
- [113] A. De Castro, R. Plant, J. Six, and J. Peña, “Mapas de calendario de cultivo y variables fenológicas mediante el análisis de imágenes modis y aster basado en objetos,” *Revista de Teledetección. Asociación Española de Teledetección*, no. 41, pp. 29–36, 2014.
- [114] M. Farrell, “Avances de la agricultura por ambientes en la región semiárida pampeana.,” *Ediciones INTA*, 2012.
- [115] A. De la Casa and G. Ovando, “Integración del Índice de vegetación de la diferencia normalizada (ndvi) y del ciclo fenológico del maíz para estimar el rendimiento a escala departamental en córdoba, argentina,” *Agricultura Técnica - Chile*, vol. 67, pp. 4:362–371, 2007.
- [116] C. Daughtry, P. Doraiswamy, E. Hunt Jr., A. Stern, J. McMurtrey III, and J. Prueger, “Remote sensing of crop residue cover and soil tillage intensity,” *Soil and Tillage Research*, vol. 91, no. 1–2, pp. 101 – 108, 2006.
- [117] G. Serbin, C. Daughtry, E. Hunt, D. Brown, and G. McCarty, “Effect of soil spectral properties on remote sensing of crop residue cover,” *Soil Science Society of America Journal*, vol. 73, no. 5, 2009.
- [118] H. Yuan, C. Van Der Wiele, and S. Khorram, “An automated artificial neural network system for land use/land cover classification from landsat tm imagery.,” *Remote Sensing*, no. 1, pp. 243–265, 2009.
- [119] G. Satalino, D. Impedovo, A. Balenzano, and F. Mattia, “Land cover classification by using multi-temporal cosmo-skymed data.,” *6th International Workshop on the IEEE.*, pp. 17–20, 2011.
- [120] G. Satalino, R. Panciera, A. Balenzano, F. Mattia, and J. Walker, “Cosmo-skymed multi-temporal data for land cover classification and soil moisture retrieval over an agricultural site in southern australia.,” *Geoscience and Remote Sensing Symposium (IGARSS), IEEE International*, pp. 5701–5704, 2012.
- [121] M. Salvia, H. Karszenbaum, F. Grings, and P. Kandus, “Datos satelitales ópticos y de radar para el mapeo de ambientes en macrosistemas de humedal,”
- [122] L. Dengsheng, M. Batistella, E. Li, G. anda Moran, S. Hetrick, C. Costa Freitas, L. Vieira Dutra, and S. Siqueira Sant’Anna, “Land use/cover classification in the brazilian amazon using satellite images.,” *Pesqui Agropecu Bras.*, vol. 47, no. 9, 2012.
- [123] J. Soria-Ruiz, Y. Fernandez-Ordoñez, and I. Woodhousec, “Land-cover classification using radar and optical images: a case study in central mexico.,” *International Journal of Remote Sensing.*, vol. 31, pp. 3291–3305, 2010.

-
- [124] C. Schotten, L. Janssen, and G. Nieuwenhuis, "Comparison of optical and microwave satellite data for land cover inventory purposes using digital field.," *Remote Sensing*, vol. 2, no. 3, 1993.