

Mapeo remoto multisensor de coberturas agrícolas extensivas en la zona central de Córdoba

Por Miguel Martín Nolasco

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

MAGÍSTER EN APLICACIONES ESPACIALES DE ALERTA
Y RESPUESTA TEMPRANA A EMERGENCIAS

Córdoba, 2018

©IG - CONAE/UNC 2018

© FAMAFA - UNC 2018

Director: *Dr. Carlos Scavuzzo*
Co – Directora: *Mgter. Mónica Bocco*



Mapeo remoto multisensor de coberturas agrícolas extensivas en la zona central de Córdoba por [Miguel Martín Nolasco](#) se distribuye bajo una [Licencia Creative Commons Atribución-CompartirIgual 4.0 Internacional](#).

*Desde ese momento en el que el tiempo se
detuvo, cada día de nuestra vida te
tenemos muy presente en nuestro
corazón. Seguimos aprendiendo de tu
constancia, fortaleza, trabajo y amor.
Gracias por tu ayuda para poder vivir,
no solo existir.*

Agradecimientos

Una investigación de este tipo requiere amplios recursos, apoyo y motivación. Por lo tanto, aprovecho esta oportunidad para agradecer a las personas e instituciones que me han alentado y apoyado durante el transcurso de esta gran etapa de mi vida.

Mi profunda gratitud al mentor de este trabajo el Dr. Carlos Marcelo Scavuzzo por su inspiración en la redacción de la propuesta de investigación, sus enseñanzas, motivación y ayuda para llevar esta tesis a su forma final. Mi eterno agradecimiento a la Msc. Mónica Bocco por su apoyo, guía y aliento para adentrarme en este mundo de la investigación. Aprecio mucho su constante preocupación, sugerencias, comentarios y críticas constructivas para este trabajo, como su vasta paciencia. Verdaderamente es una gran fuente de afecto. Un gran aprecio al Prof. Giovanni Laneve y al MSc. Pablo Marzalletti por su predisposición a recibirme como pasante, incluirme en su grupo de trabajo, y compartirme desinteresadamente sus conocimientos.

Agradezco a la Universidad Nacional de Córdoba, a la Comisión Nacional de Actividades Espaciales, y al Instituto Gulich por brindar la oportunidad de cursar tan prestigiosa y categórica carrera. Al personal de Instituto Gulich, por sus enseñanzas, amistad constante calidez. También a la Msc. Fernanda Garcia por su acompañamiento, orientación y supervisión.

A mis amigos, y al grupo de investigación de la cátedra de estadística por el aguante, su ayuda y presencia incondicional.

Un reconocimiento para mis compañeros de cursado, que hicieron de esta una muy valiosa e inolvidable experiencia. Aprendimos a compartir nuestros conocimientos, ayudarnos mutuamente, y al día de hoy seguimos comunicándonos y trabajando juntos.

Muy especialmente a mi familia por estar presente en todo momento y lugar, apoyándome y entendiéndome en cada etapa de mi vida.

Muchas gracias

Resumen

En la provincia de Córdoba, Argentina, los cultivos de soja y maíz son los más importantes, abarcando el 93% de la superficie sembrada. El uso de sensores remotos permite el mapeo y monitoreo de cultivos en grandes superficies. La capacidad de identificación por especie y en tiempo casi real es deseable. En la presente tesis se describe el uso práctico de la teledetección en el mapeo de cultivos, mediante el uso de sensores pasivos y activos. Los objetivos fueron:

- Evaluar y comparar el desempeño de algoritmos de clasificación paramétricos y no paramétricos, y el efecto de la naturaleza de las clases a ingresar en los modelos.
- Determinar la posibilidad de extrapolar firmas espectrales a otras campañas agrícolas.
- Caracterizar cubiertas de residuos de cultivos agrícolas¹ utilizando imágenes SAR.

El estudio fue desarrollado en el área central de la Provincia de Córdoba, Argentina. Se utilizaron imágenes de los sensores Landsat 8, Landsat 7 y de la constelación Cosmo Skymed. Los algoritmos de clasificación empleados fueron: Máxima Verosimilitud, Support Vector Machine y Random Forest. La precisión de las clasificaciones fue evaluada mediante la construcción de matrices de confusión.

Los resultados de la clasificación utilizando datos del mismo periodo de tiempo, revelan la posibilidad de mapear la diversidad de coberturas agrícolas presentes, con anterioridad al momento de finalización de sus ciclos. Los mejores índices de precisión se alcanzaron al utilizar grupos de entrenamiento-validación, cuyas clases representaban los diversos estadios fenológicos de cada cultivo. Se determina la conveniencia del algoritmo clasificador de Máxima Verosimilitud, el cual alcanzó excelentes resultados, fue de ejecución simple y de bajo costo computacional. Respecto a la clasificación realizada con datos inter-anales, el mapa resultante evidenció un Índice Kappa catalogado como “muy bueno”, y una precisión global del 90%. Los resultados confirman, una vez más, la ventaja de considerar los estadios fenológicos de cada cultivo en la determinación de las clases a analizar. En especial considerar los correspondientes a momentos de iniciación de la etapa reproductiva, en los cuales es posible una mejor discriminación.

Respecto a la evaluación de la aplicabilidad de datos de radar, las pruebas de reducción del “ruido” speckle, determinaron que el filtro Lee es el más apropiado para el problema bajo estudio. Los datos en polarización HH permitieron una mejor discriminación de las clases de cobertura *rastrojo de soja* y *rastrojo de maíz*. Cuando se analizaron las diferencias absolutas de los valores de retrodispersión y el Número Equivalente de Looks de una imagen, se pudo aseverar con un nivel de confianza del 95% que los dos tipos de coberturas eran diferentes. Para lograr una mejor separación de las diversas clases fue decisivo el contenido de humedad de los residuos. Por último, si se desea mapear cultivos de invierno que se encuentran en etapas finales de sus ciclos, es más adecuado trabajar con ambas polarizaciones (HH-VV).

Palabras Clave: Machine Learning, Maxima Verosimilitud, Landsat 8, Landsat 7, Cosmo Skymed, Soja, Maíz, Clasificación.

¹El término “cubierta de residuos de cultivos agrícolas”, hace referencia al conjunto de restos de tallos y hojas que quedan en el terreno tras cosechar un cultivo. Se lo conoce comúnmente como “rastrojo”.

Abstract

In the province of Córdoba, Argentina, the most important crops are soybean and corn, which covers 93% of the planted area. The use of remote sensors allows the mapping and monitoring of crops in large areas. The ability to identify different species and in almost real time is desirable. This thesis describes the practical use of remote sensing in crop mapping, using passive and active sensors. The objectives were:

- Evaluate and compare the performance of parametric and non-parametric classification algorithms, and the effect of the classes to use as input in the models.
- Determine the applicability of spectral signatures to other campaigns.
- Characterize crop residue covers² using SAR images.

The study was conducted in the central area of the Province of Córdoba, Argentina. Landsat 8, Landsat 7 and the Cosmo Skymed images were used. The classification algorithms used were: Maximum Likelihood, Support Vector Machine and Random Forest. The accuracy of the classifications was evaluated by confusion matrices.

The results of the classification using data from the same time period, reveal the possibility of mapping the diversity of the present agricultural coverage, prior to the moment of completion of their cycles. The best precision indexes were reached using training-validation groups, whose classes represented the different phenological stages of each crop. The convenience of the Maximum Likelihood classifier algorithm is determined, it achieved excellent results, had a simple execution and low computational cost. Regarding classification algorithms using inter-annual data, the resulting map showed a Kappa Index classified as "very good", and an overall accuracy of 90%. The results confirm once again the advantage of considering the phenological stages of each crop in the determination of the classes to be analyzed. Specially to consider those corresponding to the beginning of the reproductive stage, in which a better discrimination is possible.

With respect to the evaluation of the applicability of radar data, the speckle "noise" reduction tests determined that the Lee filter is the most appropriate one for the problem under study. The polarized HH data allowed a better discrimination of the soybean and corn stubble coverage classes. When the absolute differences of the backscatter values and the Equivalent Number of Looks of an image were analyzed, it could be determined with a confidence level of 95% that the two types of coverage were different. To achieve a better separation of the various classes, the moisture content of the waste was critical. Finally, in order to map winter crops, which are in the final stages of their cycles, it is more appropriate to work with both polarizations (HH-VV).

Keywords: Machine Learning, Maximum Likelihood, Landsat 8, Landsat 7, Cosmo Skymed, Soybean, Corn, Classification.

² The term "crop residue cover" refers to stems and leaves remains in the field after harvesting a crop. It is commonly known as "stubble".

ÍNDICE GENERAL

AGRADECIMIENTOS	2
RESUMEN	3
ABSTRACT	4
ÍNDICE GENERAL	5
ÍNDICE DE FIGURAS	8
ÍNDICE DE TABLAS	11
LISTA DE ACRÓNIMOS	12
INTRODUCCIÓN	13
HIPÓTESIS	15
OBJETIVO GENERAL	15
<i>Objetivos específicos</i>	15
ARGUMENTACIÓN Y ESTRUCTURA DE LA PRESENTE TESIS	15
MARCO TEÓRICO	17
ÁREA DE ESTUDIO	17
<i>Ambiente</i>	17
Vegetación natural	18
Suelos	18
Aptitud de uso	18
Clima	18
<i>Estructura agraria</i>	19
Explotaciones Agropecuarias y superficie por estrato de tamaño	19
Formas de tenencia de la tierra	19
<i>Principales producciones agropecuarias</i>	19
FENOLOGÍA DE LOS CULTIVOS DE SOJA Y MAÍZ	20
<i>Estadios de desarrollo del cultivo de Maíz</i>	20
Estrategias de producción determinantes del ciclo del cultivo de maíz	25
<i>Estadios de desarrollo del cultivo de Soja</i>	25
Estrategias de producción determinantes del ciclo del cultivo de soja	30
SENSORAMIENTO REMOTO	31
<i>Principios del espectro electromagnético en teledetección</i>	32
SENSORES UTILIZADOS EN LA PRESENTE TESIS	34
<i>Características de las imágenes</i>	35
REVISIÓN DE ALGORITMOS DE CLASIFICACIÓN DE CULTIVOS AGRÍCOLAS A PARTIR DE IMÁGENES SATELITALES	39
INTRODUCCIÓN	39
ENFOQUES DE PROCESAMIENTO	40
<i>Algoritmos de clasificación derivados del aprendizaje automático</i>	40
Random Forest	41
Support Vector Machine	43
El uso de Kernels en datos no separables linealmente	44
<i>Enfoque de análisis orientado a objetos</i>	45
Región de crecimiento:	45
El algoritmo “ <i>meanshift</i> ”	45
MAPEO DE CULTIVOS AGRÍCOLAS EN BASE A DATOS ESPECTRALES Y DE VERDAD DE TERRENO CONTEMPORÁNEOS	47

MATERIALES Y MÉTODOS	48
<i>Procesamiento de los datos de entrada</i>	48
Datos satelitales	48
Datos de referencia a terreno	48
Estado de los cultivos al momento del muestreo a campo	49
<i>Clasificación no supervisada utilizando el algoritmo K-means</i>	51
<i>Metodología de clasificación supervisada</i>	53
<i>Validación</i>	55
RESULTADOS Y DISCUSIÓN.....	56
<i>Clasificación supervisada utilizando algoritmo de Máxima Verosimilitud</i>	56
<i>Clasificación supervisada utilizando algoritmo Random Forest</i>	61
<i>Clasificación supervisada utilizando el algoritmo Support Vector Machine</i>	66
<i>Comparación del desempeño entre algoritmos</i>	70
SÍNTESIS	71

MAPEO DE CULTIVOS AGRÍCOLAS EN BASE A DATOS ESPECTRALES Y DE VERDAD DE TERRENO NO CONTEMPORÁNEOS 73

MATERIALES Y MÉTODOS	73
<i>Área de estudio</i>	73
<i>Procesamiento de los datos de entrada</i>	74
Datos satelitales	74
Datos de referencia a terreno	74
<i>Análisis, depuración y generación del nuevo conjunto de datos de referencia a campo</i>	74
Segmentación	74
Selección de lotes y extracción de estadísticos	75
Generación de nuevo conjunto de verdad de terreno	75
<i>Metodología de clasificación utilizada</i>	75
Algoritmo de clasificación.....	75
Validación	76
RESULTADOS Y DISCUSIÓN.....	78
<i>Segmentación</i>	78
<i>Firmas espectrales representativas</i>	80
<i>Análisis de distancias</i>	83
<i>Clasificación</i>	84
<i>Evaluación de la precisión de la clasificación</i>	87
SÍNTESIS	91

UNA PRIMERA APROXIMACIÓN AL ANÁLISIS DE COBERTURAS AGRÍCOLAS POST COSECHA POR MEDIO DE IMÁGENES SAR 92

MATERIALES Y MÉTODOS	93
<i>Datos de referencia</i>	93
<i>Descripción de los sistemas de radar de apertura sintética</i>	93
Propiedades del material superficial que afectan la respuesta de la señal	94
Interacción con la señal polarizada	95
<i>Imágenes satelitales</i>	96
<i>Pre-procesamiento de imágenes SAR</i>	96
Calibración.....	96
Multilooking	96
Filtros reductores de speckle.....	97
Correcciones Geométricas.....	97
<i>Procesamiento de los datos</i>	98
Evaluación del filtro reductor de speckle	98
Análisis espacial y temporal de la interacción entre la señal y la superficie del suelo	98
Clasificación supervisada de datos SAR	98
RESULTADOS Y DISCUSIÓN.....	100

<i>Evaluación de filtros para la reducción del speckle</i>	100
<i>Análisis de la interacción de la onda según el tipo de rastrojo</i>	103
Variación dentro y entre las clases de rastrojo.....	103
Estudio de discriminación de los tipos de residuo agrícola	106
Análisis de la variación temporal de las clases representativas	108
<i>Clasificación</i>	112
Examen del mapeo operativo de coberturas de residuos agrícolas	117
SÍNTESIS	118
CONCLUSIONES	120
PERSPECTIVAS FUTURAS	121
BIBLIOGRAFÍA	122
APÉNDICE A	135
MATRICES DE CONFUSIÓN CALCULADAS PARA CADA MODELO DE CLASIFICACIÓN EVALUADO.	135
<i>Máxima Verosimilitud (ML_4)</i>	135
<i>Máxima Verosimilitud (ML_5)</i>	136
<i>Máxima Verosimilitud (ML_6)</i>	137
<i>Máxima Verosimilitud (ML_7)</i>	138
<i>Random Forest (RF_4)</i>	139
<i>Random Forest (RF_5)</i>	140
<i>Random Forest (RF_6)</i>	141
<i>Random Forest (RF_7)</i>	142
<i>Support Vector Machine (svm_4)</i>	143
<i>Support Vector Machine (svm_5)</i>	144
<i>Support Vector Machine (svm_6)</i>	145
<i>Support Vector Machine (svm_7)</i>	146
APÉNDICE B	147
VERIFICACIÓN DE LA NORMALIDAD DE LOS DATOS. SHAPIRO TEST:.....	147
APÉNDICE C	147
ANÁLISIS DE LA VARIANZA.	147
31 agosto, 2013. HH band.	147
31 agosto, 2013. VV band.....	149
APÉNDICE D	152
INTERVALOS DE CONFIANZA RADIOMÉTRICA EN FUNCIÓN DEL NÚMERO EQUIVALENTE DE LOOKS (ENL)	152

ÍNDICE DE FIGURAS

Figura 1. Mapa de ZAHs de la provincia de Córdoba (X-B Oncativo resaltada) con coordenadas geográficas próximas.	17
Figura 2. Periodos del cultivo de maíz para la región centro de Córdoba. Extraído de (Toledo 2014).	25
Figura 3. Recolección de los datos, procesamiento, análisis y uso final. Extraído de Panda et al. (2015).	31
Figura 4. Sistemas de teledetección activa, y pasiva con diferentes plataformas. Extraído de Panda et al. (2015).	32
Figura 5. Espectro electromagnético sobre el cual los sistemas de teledetección están basados (Panda et al. 2015).	33
Figura 6. Curva de reflectancia típica de la vegetación, mostrando los factores dominantes que controlan la reflectancia de la hoja. Adaptado de Vane et al. (1982).....	34
Figura 7. Configuración de una matriz mostrando el pixel (elemento de la imagen). Extraído de Panda et al. (2015).	36
Figura 8. Grafico bivariado de dependencia parcial para <i>Urtica dioica</i> . Variables: DistRoad, distancia a la carretera más cercana (m). DistTrail, distancia a la carretera o camino más cercano (m). Extraído de Cutler et al. (2007)	42
Figura 9. Las dos clases son separadas por un margen de $d_1 + d_2$, por medio de dos hiperplanos H1 y H2 con un hiperplano óptimo de separación en medio de los dos. Los vectores de soporte de las dos clases son mostradas en círculos sobre los planos H1 y H2 (Extraído de Mathur & Foody (2008) y Hofmann (2006)).....	43
Figura 10. Estadios fenológicos de los cultivos al momento de la toma de datos a campo.....	50
Figura 11. Imagen de verdad de terreno y las resultantes de clasificaciones no supervisadas..	52
Figura 12. Clasificación con algoritmo ML, umbral de probabilidad = 0.01.....	53
Figura 13. Recorte escena Landsat 8 del 23/03 sobre el área de estudio, composición color real. Se señalan lotes de cultivo con su correspondiente código de clase de cobertura.	59
Figura 14. Recortes de los mapas resultantes con los modelos MLC_5 y MLC_6.....	60
Figura 15. Firmas espectrales de las clases soja extra tardía y maní	61
Figura 16. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_5	63
Figura 17. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_6	63
Figura 18. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_4	64
Figura 19. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_7	64
Figura 20. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_4.....	67
Figura 21. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_5.....	68
Figura 22. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_6.....	68
Figura 23. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_7	69
Figura 24. Metodología de procesamiento y clasificación de datos.....	77

Figura 25. Recorte de la imagen Landsat 8 color real, sobre área de estudio, con fecha 23 marzo de 2016.....	78
Figura 26. Resultado de segmentación sobre el área de estudio. Los objetos sobreestiman el tamaño de los lotes (Encerrados con un círculo amarillo se señala varios lotes incluidos en un mismo segmento).....	79
Figura 27. Resultado de segmentación sobre el área de estudio. Se subestiman el tamaño de determinados lotes	79
Figura 28. Resultado de segmentación sobre el área de estudio elegida para la extracción de estadísticos representativos.	80
Figura 29. Firmas espectrales de clases de cobertura de cultivos (Landsat 7, 15 marzo 2016). 81	
Figura 30. Recorte del área a clasificar. Imagen L8 color real del 16 de abril de 2013.....	84
Figura 31. Mapa de cultivos resultantes de la clasificación interanual.....	85
Figura 32. Mapa de cultivo sometido a una regularización con filtro de mayoría de 3x3.....	86
Figura 33. Mapa de cultivo sometido a una regularización con filtro de mayoría de 5x5.....	86
Figura 34. Representación del campo eléctrico y polarización. Fuente: Canada Center for Remote Sensing (2014).	94
Figura 35. Mecanismos de dispersión para ondas de longitud corta: a) difusa superficial, b) en profundidad, c) doble rebote, y d) volumétrica (extraído de Richards (2013)).	95
Figura 36. Áreas de clasificación con las correspondientes fechas de adquisición de las imágenes intervinientes.....	99
Figura 37. Diferencia porcentual entre el valor medio de los pixeles de la imagen original y filtradas (rastrajo de maíz).	100
Figura 38. Diferencia porcentual entre el valor medio de los pixeles de la imagen original y filtradas (rastrajo de soja).	100
Figura 39. Desviación estándar de la imagen original, y filtradas (rastrajo de maíz).	101
Figura 40. Desviación estándar de la imagen original, y filtradas (rastrajo de soja).	101
Figura 41. Diferencia absoluta entre las medias de la imagen filtrada y original (rastrajo maíz).	101
Figura 42. Diferencia absoluta entre las medias de la imagen filtrada y original (rastrajo soja).	102
Figura 43. Recortes de las imágenes resultantes de aplicar los distintos filtros (imagen original: polarización HH, 31 agosto).	103
Figura 44. Diagramas de caja para los valores de retrodispersión (polarización HH) de los diversos lotes.	104
Figura 45. Diagramas de caja para los valores de retrodispersión (polarización VV) de los diversos lotes.	105
Figura 46. Captura de los principales tipos de rastros en el área de estudio.	106
Figura 47. Histograma de valores de retrodispersión (dB) para un lote con rastrojo de maíz. 31 de agosto, polarización HH.	107
Figura 48. Histograma de valores de retrodispersión (dB) para un lote con rastrojo de soja. 31 de agosto, polarización HH.	108
Figura 49. Histograma de valores de retrodispersión (dB) para los lotes con rastrojo de maíz (naranja) y soja (verde). 31 de agosto, polarización HH.	108
Figura 50. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_2b". Rastrojo de maíz, polarización HH.	109
Figura 51. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_3b". Rastrojo de maíz, polarización HH.	109

Figura 52. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_4". Rastrojo de maíz, polarización HH.	109
Figura 53. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_3". Rastrojo de soja, polarización HH.	110
Figura 54. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_5". Rastrojo de soja, polarización HH.	110
Figura 55. Imagen óptica (25/10/2013) y SAR (26/10/2013) sobre el área de estudio.	111
Figura 56. Comienzo labores de siembra (imagen CNES/Airbus, adquirida el 15 de noviembre de 2013).	114
Figura 57. Estado de los lotes al momento del muestreo efectuado el 20 de noviembre de 2013.....	114
Figura 58. PP, PU y κ alcanzados para cada tipo de cobertura en el área 1, 2 y 3.....	117
Figura 59. Intervalos de confianza de acuerdo al NEL y la diferencia en dB. Extraído de Laur et al. (2004)	152

ÍNDICE DE TABLAS

Tabla 1. Superficie (en %) de suelos de la ZAH X-B Oncativo según capacidad de uso. Extraído de Daza (2009).	18
Tabla 2. Estadios vegetativos del cultivo de maíz.	21
Tabla 3. Estadios reproductivos del cultivo del maíz.	23
Tabla 4. Estadios vegetativos del cultivo de soja	26
Tabla 5. Estadios reproductivos del cultivo de soja.	28
Tabla 6. Elementos y factores involucrados en la teledetección. Lillesand et al. (2004).....	32
Tabla 7. Características de los productos satelitales utilizados en la presente tesis (Chander et al. 2009; Ariza 2013; Covello et al. 2010).....	38
Tabla 8. Descripción de productos internos de Kernels. Adaptado de Hofmann (2006).	44
Tabla 9. Descripción de los modelos de clasificación no supervisada ejecutados.....	51
Tabla 10. Clases utilizadas en los modelos de clasificación con el algoritmo de Máxima Verosimilitud (MLC).....	54
Tabla 11. Clases y parámetros utilizados en los modelos de clasificación con el algoritmo RF .	54
Tabla 12. Clases y parámetros utilizados en los modelos de clasificación con SVM	55
Tabla 13. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con MLC	56
Tabla 14. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con RF	61
Tabla 15. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con SVM	66
Tabla 16. Fechas de adquisición de imágenes	74
Tabla 17. Valores de los estadísticos mediana y desvío estándar (DE) de cada banda de la imagen L7 (fecha de adquisición 15/03/2016) para los tipos de cobertura en valores de reflectancia. Se acompaña su respectiva magnitud de NDVI.	82
Tabla 18. Clases y atributos del nuevo conjunto de entrenamiento	83
Tabla 19. Matriz de clasificación del mapeo realizado a partir de la imagen L8 de 16 de abril..	87
Tabla 20. Matriz de clasificación post regularización con filtro de mayoría 3x3.	87
Tabla 21. Matriz de clasificación post regularización con filtro de mayoría 5x5.	87
Tabla 22. Valores de los estadísticos de validación para los mapas de cultivos	90
Tabla 23. Correspondencias entre magnitudes físicas/radiométricas.....	94
Tabla 24. Fechas de viaje de muestreo a campo y adquisición de imágenes SAR sobre el área de estudio.....	96
Tabla 25. Medidas resumen filtro Lee 5x5 en decibeles (dB) e Intensidad (σ_0), para los estadísticos media, desvío estándar y número equivalente de looks, para los rastros de soja y maíz.	107
Tabla 26. Porcentaje de humedad presente en el rastrojo de maíz (amarillo) y rastrojo de soja (verde) de los diferentes lotes registrados, según fecha de muestreo.....	113
Tabla 27. Estadísticos de validación de la precisión de la clasificación en el área 1, según polarización utilizada.....	115
Tabla 28. Estadísticos de validación de la precisión de la clasificación en el área 2, según polarización utilizada.....	115
Tabla 29. Estadísticos de validación de la precisión de la clasificación en el área 3, según polarización utilizada.....	115
Tabla 30. Estadísticos de validación de la precisión de la clasificación en el área 4, según polarización utilizada.....	116

LISTA DE ACRÓNIMOS

CONAE	Comisión Nacional de Actividades Espaciales
DN	Digital Number
EEM	Espectro Electromagnético
FAO	Food and Agriculture Organization
FCA	Facultad de Ciencias Agropecuarias
GM	Grupo de Madurez
GSD	Ground Sample Distance
ha	Hectárea
HH	Radiación electromagnética polarizada, emitida y recibida en el plano horizontal
INDEC	Instituto Nacional de Estadística y Censos de la República Argentina
INTA	Instituto Nacional de Tecnología Agropecuaria
MLC	Maximum likelihood Classifier
NDVI	Normalized Difference Vegetation Index
NEL	Número Equivalente de Looks
NSR	Noise Signal Ratio
PG	Precisión Global
REM	Radiación Electromagnética
RF	Random Forest
SAR	Synthetic Aperture Radar
SLC	Scan Line Corrector
SVM	Support Vector Machine
UN	United Nations
UNC	Universidad Nacional de Córdoba
VV	Radiación electromagnética polarizada, emitida y recibida en el plano vertical
ZAH	Zonas Agroeconómicas Homogéneas
κ	Índice Kappa
λ	Longitud de onda
μm	Micrómetro
σ^0	Coefficiente de retrodispersión

Capítulo 1

Introducción

Los agro-ecosistemas cubren más de la tercera parte de la superficie terrestre libre de hielo y constituyen el tipo de uso de suelo dominante sobre la tierra (FAOSTAT 2011). La agricultura y los recursos naturales, se encuentran ambos, bajo una fuerte presión. Los principales factores son el crecimiento demográfico, el aumento del consumo de dietas intensivas en calorías – y carne-, y un uso cada vez mayor de las tierras de cultivo para la producción de bioenergía (Foley et al. 2011; Pelletier & Tyedmers 2010; FAO 2010). Teniendo en cuenta que el tipo de explotación trae aparejada consecuencias directas sobre la sustentabilidad de los recursos naturales (Di Pace 1992), uno de los retos más importantes para los agrónomos, agricultores y otros participantes de la cadena productiva consiste en satisfacer la necesidad humana de alimentos y fibras, así como la demanda acelerada de energía, de una manera ecológicamente sostenible (Miller 2008). Para monitorear el progreso de las adaptaciones necesarias a estos desafíos, evitando vacíos de información, se hace necesario poseer sistemas de monitoreo agrícola apropiados. Los tomadores de decisiones requieren información sobre el estado del sector agrícola y los hechos que condujeron a la situación actual. La información, también es fundamental para ejecutar evaluaciones en relación al impacto real de políticas e inversiones. Tener a disposición datos confiables también facilita la reducción del riesgo y podría dar lugar a análisis estadísticos optimizados en un rango de escalas, lo que permitiría un oportuno y preciso reporte estadístico (Atzberger et al. 2015).

En el contexto de la producción agrícola una actividad de manejo clave efectuada por los agricultores es el desarrollo de planes de rotaciones de cultivos, basados en oportunidades económicas y adaptados, idealmente, a las condiciones específicas de cada tipo de ambiente (Sahajpal et al. 2014). La rotación de cultivos es definida como la práctica de siembra de una secuencia de especies de plantas en la misma tierra (Wibberley 1996; Bullock 1992). Estas secuencias generan ciclos de periodo de tiempo determinado -por ejemplo, cada dos, tres, o cuatro años- (Leteinturier et al. 2006). Si bien la rotación de cultivos se realiza desde hace miles de años (MacRae & Mehuys 1985), los patrones actuales son mucho más simples y se aplican a una menor diversidad de cultivos (Plourde et al. 2013). En comparación con un sistema de monocultivo suplementado con niveles óptimos de nutrientes, la rotación permite generalmente lograr mayores rendimientos (Porter et al. 1997), principalmente atribuidos a la mejora en las propiedades físicas del suelo y su fertilidad (Pierce & Rice 1988), así como al control optimizado de plagas, enfermedades y malezas (Tilman et al. 2002). Cuando la rotación de cultivos se practica en forma conjunta con un régimen de baja intensidad de labranza, se acumula sobre el suelo un abundante rastrojo en descomposición, el cual puede constituir una importante fuente de nutrientes para los cultivos sucesivos (Alvarez et al. 2014). Por otro lado, también puede aumentar la disponibilidad de agua como consecuencia de la estabilización de las propiedades hidráulicas y la disminución de las tasas de evaporación en suelos (Salado-Navarro et al. 2012; Lozano et al. 2014). A nivel local, en la provincia de Córdoba, Argentina, los cultivos de soja y maíz son los más importantes, abarcando el 93% de la superficie sembrada

(Ministerio de Agroindustria de la Nación n.d.). En este escenario se ha demostrado que la implementación de la rotación como práctica de manejo contribuye a aumentar los rindes en la región central de la provincia de Córdoba (Basanta & Alvarez 2015). En contraposición, la práctica del monocultivo con labranza está asociada a un mayor grado de erosión de los suelos (Sanzano et al. 2008). Estos estudios dan cuenta del renovado interés en la rotación de cultivos y la siembra directa en los últimos tiempos.

Históricamente, la información relativa a la superficie ocupada por cultivos anuales se ha reunido en base a encuestas en terreno; sin embargo, la realización de estudios de este tipo sobre patrones de rotación a gran escala sería muy costoso y los mismos no pueden proporcionar información sobre la distribución de diferentes tipos de cultivos a resoluciones espaciales finas. Por estos motivos la literatura sobre este tipo de análisis a escala regional o nacional es prácticamente inexistente (Plourde et al. 2013). En este contexto la teledetección por satélite ha progresado enormemente desde que Landsat 1 fue puesto en órbita en 1972. Más aún, por mucho tiempo, el desarrollo de las tecnologías de teledetección basadas en satélites estuvo conducido por las necesidades de información agrícola (Becker-reshef et al. 2010). La importancia de la teledetección en el estudio de las actividades agrícolas, se explica en que estas se enfrentan a desafíos específicos que no son comunes a otros sectores económicos, como su dependencia del entorno físico (clima y suelo), de los ciclos estacionales (primavera, verano, otoño e invierno), la presencia de bio factores adversos (plagas, malezas, enfermedades) y la naturaleza perecedera de algunos productos (Atzberger et al. 2015). A pesar de que muchos objetos naturales tienen características comunes en sus curvas de reflectancia espectral, lo cual dificulta su identificación y separación, las diferencias sutiles y su varianza en el tiempo permiten su clasificación (Bowker et al. 1985). En los últimos años, ha sido posible realizar estudios multi-temporales de grandes superficies a partir del uso de imágenes satelitales (Nolasco et al. 2016). Esto, integrado a sistemas de información geográfica y la aplicación de agricultura de precisión, lleva a la mejora de los rendimientos agrícolas y conjuntamente minimiza el deterioro de los recursos naturales (Altieri & Nicholls 2013). Actualmente la teledetección está permitiendo la adquisición de información oportuna, completa, objetiva, transparente, precisa y no sesgada. Esta información puede finalmente evitar la especulación excesiva del mercado y la consiguiente alza de precios (Naylor 2011). Esto demuestra que la teledetección tiene más que ofrecer que sólo ser un componente ecológico y económico en los sistemas de monitoreo (Atzberger et al. 2015).

Si bien existe un gran número de aportes sobre el mapeo de tierras de cultivo en base a múltiples estrategias de clasificación de cobertura terrestre (Waldner et al. 2015), la mayoría se vale de métodos supervisados que dependen, en gran medida, de datos in situ o de la interpretación humana de firmas espectrales, haciendo el proceso de clasificación intensivo en el uso de recursos, y difícil de repetir en el tiempo y espacio (Zhong et al. 2014; Bocco et al. 2007; Nolasco et al. 2016). Estos métodos supervisados generalmente superan en precisión a los no supervisados (Bocco et al. 2012). Específicamente los algoritmos de clasificación derivados del aprendizaje automático al ser independientes de los supuestos de distribución de datos, pueden mejorar la precisión y efectividad del proceso de clasificación (Tatsumi et al. 2015; Bocco et al. 2007; Cutler et al. 2007). Sin embargo su dependencia de datos de entrenamiento pertenecientes a la misma estación y la disponibilidad de imágenes libres de nubosidad constituye un inconveniente a la hora de realizar monitoreos operativos. Por este motivo resulta imprescindible analizar constantemente la disponibilidad de metodologías alternativas (Zhong et al. 2014). En este sentido, la extrapolación temporal de patrones de índice verde está siendo indagada para el mapeo de commodities agrícolas (Zhong et al. 2016). Por otra parte el uso de

imágenes de radar de apertura sintética (*Synthetic Aperture Radar*) es útil para el mapeo y monitoreo de residuos en el periodo de barbecho³, debido en gran medida a la alta sensibilidad de las microondas a las condiciones del suelo (Zheng et al. 2015). La señal recibida por el radar es principalmente afectada por las características estructurales y las propiedades dieléctricas de los objetos de la superficie, permitiendo identificar rasgos complementarios a los detectables por medio de sensores ópticos. Debido a que los residuos son considerados vegetación “muerta”, su efecto sobre la retrodispersión es considerado insignificante. Sin embargo, cuando dicho residuo posee mayor contenido de agua pueden detectarse y cuantificarse alteraciones en esta retrodispersión de las ondas emitidas por el instrumento (McNairn et al. 2001). En especial, la banda X puede ser útil para el mapeo diferencial de residuos de cultivos, particularmente en el caso de aquellos que se presentan como partículas de menor tamaño (Narayanan et al. 1992).

Hipótesis

En el área central de la provincia de Córdoba el uso de metodologías y protocolos de clasificación que integran imágenes de diversos sensores satelitales y algoritmos derivados del aprendizaje automático, permiten determinar el tipo de cultivo de forma eficaz y precisa.

Objetivo general

Evaluar metodologías y protocolos de clasificación de tipos de cobertura de uso agrícola, a partir de sensores satelitales pasivos y activos, que permitan detectar y cuantificar cambios espacio-temporales en el uso del suelo agrícola en la región central de la Provincia de Córdoba, Argentina.

Objetivos específicos

1. **Comparar metodologías de clasificación de cubiertas agrícolas mediante el uso de imágenes de sensores remotos, utilizando datos de campo contemporáneos a la fecha de adquisición.**
2. **Analizar la factibilidad de metodologías de clasificación de cubiertas agrícolas mediante el uso de imágenes de sensores remotos, empleando datos de entrenamiento (de terreno y satelitales) no contemporáneos.**
3. **Caracterizar cubiertas de residuos de cultivos agrícolas utilizando imágenes SAR, y validar su aplicación en el área agrícola central de la provincia de Córdoba (Argentina).**
4. **Proponer, a partir de la integración de información obtenida de los sensores ópticos y radar, futuras tareas a fin especificar protocolos que permitan generar mapas regionales de evolución del estado de cobertura del suelo de uso agrícola.**

Argumentación y estructura de la presente Tesis

Las actividades llevadas a cabo en el presente trabajo de tesis se enmarcan en el proyecto de investigación “*Desarrollo, Evaluación y Aplicación de modelos para estimar variables agronómicas*” SeCyT-UNC 2014-2015. Para este proyecto se planificaron y realizaron salidas de muestreo a campo cada 15 días por un lapso de un año calendario, a partir de setiembre de 2013. Estas salidas coincidían en mayor o menor medida con las fechas de adquisición de un sensor SAR. En el mencionado proyecto se realizó un estudio sobre identificación de cultivos de verano a través del uso de imágenes satelitales ópticas y de radar (Violini 2016). Es por ello que se consideró conveniente hacer uso de los datos de campo e imágenes SAR precedentes a la campaña agrícola estival, para el análisis de residuos de cultivo post cosecha. Sin embargo, solo se disponía del

³ Técnica por la cual la tierra se deja sin sembrar o cultivar durante uno o varios ciclos vegetativos.

registro de 17 lotes agrícolas, los cuales mayoritariamente habían sido cultivados con soja. Por consiguiente, se hizo necesario generar datos de referencia a campo para la campaña agrícola 2012-2013, para así poder realizar un adecuado análisis de las imágenes SAR. Para ello se utilizaron datos de referencia a campo e imágenes satelitales de la campaña agrícola 2015-2016, cuyos datos espectrales fueron extrapolados a los de la campaña de interés (2012-2013). Debido a la presencia de nubosidad intensa en algunas fechas del estudio, y el daño presente en el sensor Landsat 7 (scan line corrector failure) (Hossain et al. 2015), se utilizaron en conjunto imágenes procedentes del sensor Landsat 7 y Landsat 8.

Realizados estos comentarios preliminares, a continuación, se procede con la descripción de la estructura del presente trabajo de tesis. El mismo ha sido organizado en función de los objetivos específicos propuestos.

En el capítulo 2 se realiza una descripción socio-ambiental del área de estudio, se presentarán los conceptos agronómicos relativos a los cultivos bajo análisis, se expone una introducción al sensoramiento remoto y una descripción de los datos satelitales utilizados. En el capítulo 3 se describen las características de los algoritmos de clasificación (convencionales y derivados del aprendizaje automático), y de segmentación, mencionando antecedentes de su utilización en el mapeo de áreas agrícolas. En el capítulo 4 se presentan los resultados de la evaluación de distintas estrategias de clasificación por uso-cobertura del suelo haciendo uso de imágenes Landsat 8 y datos de la campaña agrícola 2015-2016. En el capítulo 5 se presentan los resultados de las clasificaciones de datos satelitales correspondientes a la campaña agrícola 2012-2013, en base a datos espectrales y de referencia a campo de la campaña 2015-16. En el capítulo 6 se realiza un primer análisis de la utilización de imágenes de radar en banda X para el estudio de residuos de cultivos post cosecha. Finalmente, en el capítulo 7, se establecen las conclusiones y consideraciones finales del presente trabajo tesis. Adicionalmente se señalan futuras líneas de trabajo para la generación de mapas regionales de evolución del estado de cobertura del suelo de uso agrícola.

Capítulo 2

Marco teórico

Área de estudio

Para poder comprender la diversidad de sistemas productivos sobre los que descansa la producción agropecuaria en el área de estudio, se recurrió a un estudio/caracterización desarrollado por el Instituto Nacional de Tecnología Agropecuaria. Este reconoce a las condiciones naturales, sociales, económico productivas e institucionales como primeras determinantes de la diversidad, sostenibilidad y competitividad de los sistemas de producción. En función del grado de abstracción u homogeneidad que presentan esas condiciones se distinguen cinco Macro o Ecorregiones, quince Regiones (coincidentes con las áreas de influencia de cada uno de los Centros Regionales del INTA) y dieciséis Zonas Agroeconómicas Homogéneas -ZAH- (Daza 2009).

El área de estudio se encuentra dentro de la Zona Agroeconómica Homogénea X-B Oncativo, la misma se ubica en la región central de la provincia de Córdoba (Figura 1), comprende la totalidad de los departamentos Río Segundo y Tercero Arriba.




Figura 1. Mapa de ZAHs de la provincia de Córdoba (X-B Oncativo resaltada) con coordenadas geográficas próximas.

Ambiente

El área natural corresponde a la región fitogeográfica del Espinal. El relieve corresponde a la Pampa loésica. Esta va desde los 600 hasta los 200 m.s.n.m., con pendientes entre 2 y 3 por mil. Constituye un plano basculado hacia el Este, cubierto por una potente acumulación de sedimentos eólicos franco limosos (Jarsún et al. 2003). Esta surcada por cursos que nacen en las

sierras donde exhiben importantes procesos de erosión vertical y lateral, para dar luego lugar a procesos de sedimentación en áreas de derrame que suceden hacia el este (Daza 2009). En la región central de la provincia de Córdoba, en general con relieve de baja pendiente y extenso, existen intercalaciones de sectores suavemente deprimidos, vías de escurrimiento dispuestas espacialmente en varias direcciones dominantes, a las que se suman “pozos” de infiltración o charcas permanentes o semipermanentes, ubicadas en la intersección de estas vías. Como resultado, se genera una red de drenaje del tipo radial, centrípeta circular, de tipo “araña” fácilmente identificable en fotografías aéreas e imágenes satelitales (Jarsún et al. 2003).

Vegetación natural

En la zona del Espinal la vegetación nativa corresponde a pastizales con árboles aislados y algunos segmentos leñosos más o menos densos. Muy modificada por las actividades agropecuarias como la tampera y con una importante proporción de cultivos agrícolas extensivos. Analizado desde el punto de vista de las especies arbóreas, el Espinal está caracterizado por el género *Prosopis* (algarrobos, ñandubay, caldén), aunque incluye asociaciones de especies muy diferentes entre sí. Si bien la vegetación dominante es el bosque, existen paisajes variados, tales como las abras gramíneas, cañadas o esteros. La vegetación dominante es el bosque xerófilo, alternando con estepas de gramíneas duras (Cabrera 1976). Específicamente en las regiones boscosas se observa un acentuado proceso de desmonte o simplemente de degradación; este último expresado en la arbustización de los montes o en la erosión del suelo que lo sustenta, fenómeno producido generalmente por el sobrepastoreo de estos ambientes. Debe considerarse, ante la gravedad de estos procesos, que al evaluar el potencial de los bosques estos no sólo poseen riqueza maderable sino que tienen múltiples funciones ignoradas, entre las que se puede mencionar la diversidad biológica presente en estos ecosistemas, la regulación de la escorrentía superficial y la inmovilización de sustrato en áreas morfológicamente inestables (Daza 2009).

Suelos

Se trata de suelos ricos en limos y carbonato de calcio, profundos, bien drenados, fértiles y productivos, aunque poseen cierta fragilidad e inestabilidad estructural, que se manifiesta por una tendencia al encostramiento y al “planchado”. Los procesos erosivos (hídricos) son intensos y bastante generalizados sobre todo en el Oeste, donde suelen ocurrir “mallines” vinculados, en muchos casos, a líneas estructurales. Hay Hapustoles (65% entre típicos y énticos) caracterizados por la ausencia o el desarrollo incipiente de horizontes, a excepción del epipedón oscuro y moderadamente rico en materia orgánica. Hay una proporción menor de Argiustoles (3%) y Natraculfes (3%) en los campos más planos y bajos (Gorgas n.d.).

Aptitud de uso

El 84% de las tierras son agrícolas, la mayoría (72%) de Clase III. Las tierras de aptitud ganadera representan el 16% (Tabla 1).

Tabla 1. Superficie (en %) de suelos de la ZAH X-B Oncativo según capacidad de uso. Extraído de Daza (2009).

Clase	III	IV	VI	VII
Proporción	72	12	9	7

Clima

El clima se caracteriza por una temperatura media anual de 16°C, una amplitud térmica de 14°C y un período libre de heladas de 265 días. La pluviometría regional posee una distribución con

un rango de 800 mm al oeste y 850 mm al este, con una distribución estacional de tipo monzónico. El 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 al Este y 220 mm al Oeste.

Estructura agraria

Explotaciones Agropecuarias y superficie por estrato de tamaño

El Censo Nacional Agropecuario 2008 (INDEC n.d.) registró en la ZAH X-B Oncativo la existencia de 2.883 explotaciones agropecuarias, que ocupaban una superficie de 939508ha y explotaban una superficie media de 368 ha. El 20% correspondía a establecimientos de menos de 100 ha, sumando el 3% de la superficie total. El 51% de las explotaciones se encontraban en el estratos de 101 a 400 ha y la superficie media de estos establecimientos era de 228 ha.

Formas de tenencia de la tierra

El 48,7% de la superficie total censada de la ZAH X-B Oncativo era explotada bajo el régimen de propiedad, el 44,5% bajo el sistema de arrendamiento y aparcería, el 3,4% bajo contratos accidentales, y el restante 3,4% bajo otras formas.

Principales producciones agropecuarias

Las actividades agropecuarias predominantes de la ZAH X-B Oncativo son las agrícolas. Siendo la segunda región productora de soja y trigo de la provincia. También es importante la producción de maíz, sorgo y maní. Entre las actividades ganaderas bovinas predomina el tambo, la cría y el ciclo completo. La actividad porcina también ocupa un lugar relevante, debido a que la zona cuenta con el cuarto stock provincial (Daza 2009). Para la campaña 2014-2015 se registraron 588.545 ha sembradas con soja (*Glycine max* (L) Merrill) y 173.881 ha con maíz (*Zea mays* L.), abarcando el 93% del área sembrada en la ZAH X-B Oncativo (Ministerio de Agroindustria de la Nación n.d.). Es necesario e importante mencionar que según datos del Ministerio de Agroindustria de la Nación, referidos al periodo 1976 a 2014 para la ZAH en estudio, la superficie agrícola se incrementó en un 99.5%, mientras que la superficie destinada al cultivo de soja, paso de ser prácticamente inexistente a ocupar el 73% del total en los últimos años. Este fuerte proceso de agriculturización sumado a la ausencia de un plan ordenado de rotaciones en los cultivos, trajo como consecuencia la erosión y degradación de los suelos, dándose con mayor intensidad en aquellas tierras con agricultura continua (Rubiolo et al. 2006). En Argentina esta situación no es nueva. La expansión de la frontera agrícola siempre tuvo a un cultivo de alta rentabilidad como el motor del proceso.

En el área de estudio las estrategias de rotación y manejo de la fertilización, en conjunción con la siembra directa, permitieron aumentar la eficiencia en el uso del agua e incrementar el carbono orgánico del suelo. De esta manera, hoy es posible encontrar modelos agrícolas con altos niveles de intensificación (Campos 2008) que han pasado de esquemas que incluían un cultivo por año (soja – soja, soja – maíz) a sistemas que involucran tres o cuatro en dos años sucesivos:

- I. Trigo / soja – maíz – soja
- II. Trigo / soja – maíz
- III. Trigo / soja – trigo / maíz

Se observan también, en menor medida, productores que incorporan los cultivos estivales de sorgo y maní. Para el área de estudio la disponibilidad de información referente a la secuencia de cultivos en las rotaciones agrícolas es aún limitada.




Fenología de los cultivos de soja y maíz

El desarrollo de un cultivo consiste en una sucesión obligatoria de etapas o fases dadas en un orden riguroso e irreversible. Se corresponde con la iniciación de nuevos órganos, siendo un fenómeno puramente cualitativo. Llamamos ciclo de desarrollo, al conjunto de fases que van desde la germinación de la semilla hasta la floración y formación del fruto. Este ciclo comprende dos etapas bien definidas: desarrollo vegetativo y desarrollo reproductivo (Fassio et al. 1998).

Estadios de desarrollo del cultivo de Maíz

El sistema para clasificación de etapas o estadios desarrollado por Richie et al. (1982) que se presenta a continuación divide al desarrollo de la planta en vegetativo y reproductivo. Las subdivisiones del estadio vegetativo y reproductivo están ejemplificadas en las Tablas 2 y 3 respectivamente.

Tabla 2. Estadios vegetativos del cultivo de maíz.

Descripción	Descripción grafica
<p data-bbox="564 371 611 405">VE</p> <p data-bbox="509 461 667 495"><u>Emergencia</u></p> <p data-bbox="277 521 900 629">Elongación rápida del mesocotilo, el cual empuja el coleoptilo que está creciendo hasta la superficie del suelo</p> <p data-bbox="252 658 922 730">http://www.clemson.edu/extension/rowcrops/corn/guide/growth_stages.html</p>	
<p data-bbox="564 824 611 857">V1</p> <p data-bbox="501 920 675 954"><u>Primera hoja</u></p> <p data-bbox="252 981 922 1050">Primera hoja completamente expandida con el collar de la hoja visible.</p> <p data-bbox="252 1137 922 1209">http://www.clemson.edu/extension/rowcrops/corn/guide/growth_stages.html</p>	
<p data-bbox="564 1294 611 1328">V2</p> <p data-bbox="496 1402 679 1435"><u>Segunda hoja</u></p> <p data-bbox="264 1462 909 1532">Segunda hoja completamente expandida con el collar de la hoja visible.</p> <p data-bbox="252 1619 919 1691">http://www.uwex.edu/ces/ag/plantdoc/viewCase.cfm?cid=829</p>	

V3

Tercera hoja

Tercera hoja completamente expandida con el collar de la hoja visible.

<http://www.soilcropandmore.info/crops/Corn/How-Corn-Grows/>



V(n)

Enésima hoja

Enésima hoja completamente expandida con el collar de la hoja visible (la figura corresponde a V4).

<http://www.uwex.edu/ces/ag/plantdoc/viewCase.cfm?cid=829>



VT




Panojamiento

La planta de maíz alcanza su altura final y comienza la liberación del polen.

<http://www.soilcropandmore.info/crops/Corn/How-Corn-Grows/>



Tabla 3. Estadios reproductivos del cultivo del maíz.

Descripción	Descripción grafica
<p data-bbox="564 365 608 398">R1</p> <p data-bbox="429 450 746 483"><u>Emergencia de estigmas</u></p> <p data-bbox="296 512 879 584">Algunos estigmas son visibles fuera de las vainas (chala).</p> <p data-bbox="483 669 692 703">Fotografía propia</p>	
<p data-bbox="564 817 608 851">R2</p> <p data-bbox="531 902 641 936"><u>Ampolla</u></p> <p data-bbox="269 965 903 1075">La mazorca alcanzó su tamaño completo. Las barbas, habiendo completado su función de floración, se oscurecen y comienzan a secarse.</p> <p data-bbox="293 1160 879 1193">http://clipartdeck.com/img-cornstalk-clipart.php</p>	
<p data-bbox="564 1279 608 1312">R3</p> <p data-bbox="491 1364 681 1397"><u>Grano lechoso</u></p> <p data-bbox="285 1426 890 1536">El grano es externamente de un color amarillo y el fluido interno es blanco lechoso debido a la acumulación de almidón.</p> <p data-bbox="248 1621 924 1693">https://webapp.agron.ksu.edu/agr_social/eu_article.thr ock?article_id=644</p>	

R4

Grano pastoso

La continua acumulación de almidón en el endosperma provoca que el fluido interno se adquiera una consistencia pastosa.

Fotografía propia



R5

Grano dentado

Los granos se secan comenzando por la parte superior donde aparece una capa dura de almidón de color blanco.

Fotografía propia



R6




Madurez fisiológica

Todos los granos en la espiga han alcanzado su máximo peso seco o máxima acumulación de materia seca.

Fotografía propia



Tabla 4. Estadios vegetativos del cultivo de soja

Descripción	Descripción grafica
<p data-bbox="564 360 608 394">VE</p> <p data-bbox="509 450 663 483"><u>Emergencia</u></p> <p data-bbox="341 510 831 544">Cotiledones sobre la superficie del suelo.</p> <p data-bbox="261 629 911 741">http://ilsoyadvisor.com/diagnostics/2014/april/is-it-time-to-consider-using-starters-in-soybeans-to-bump-yield/</p>	
<p data-bbox="564 824 608 857">VC</p> <p data-bbox="509 913 663 947"><u>Cotiledonar</u></p> <p data-bbox="252 974 922 1041">Hojas unifoliadas desarrolladas lo suficientemente para que los bordes de las mismas no se toquen.</p> <p data-bbox="252 1126 922 1193">http://www.clemson.edu/extension/rowcrops/soybeans/guide/growth_stages.html</p>	
<p data-bbox="564 1288 608 1321">V1</p> <p data-bbox="509 1377 663 1411"><u>Primer nudo</u></p> <p data-bbox="320 1438 855 1505">Hojas totalmente desarrolladas en los nudos unifoliados.</p> <p data-bbox="395 1590 778 1657">http://blogs.ext.vt.edu/ag-pest-advisory/author/dholshou/</p>	

V2

Segundo nudo

Primera hoja trifoliada totalmente desarrollada sobre el nudo unifoliar.

<http://www.soilcropandmore.info/crops/Soybeans/SoybeanGrowthandMangement.htm>



V3

Tercer nudo

Tres nudos sobre el tallo principal con las hojas totalmente desarrolladas, contando el nudo de hojas unifoliadas.

<http://corn.agronomy.wisc.edu/Crops/Soybean/L004.aspx>



V(n)

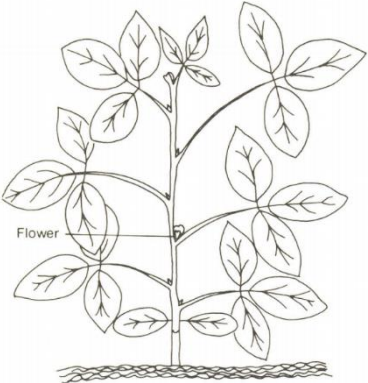
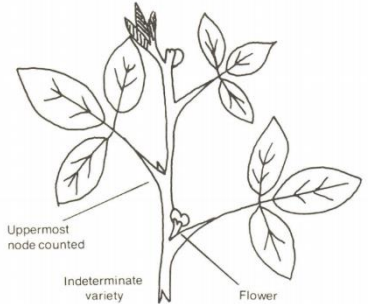


Enésimo nudo

n número de nudos en el tallo principal con las hojas totalmente desarrolladas empezando con el nudo unifoliar (la figura corresponde a V5).

<http://www.myagriguru.com/Bibliography.aspx>



Tabla 5. Estadios reproductivos del cultivo de soja.

Descripción	Descripción grafica
<p data-bbox="568 362 608 394">R1</p> <p data-bbox="491 448 684 479"><u>Inicio floración</u></p> <p data-bbox="269 510 903 542">Una flor abierta en cualquier nudo del tallo principal.</p> <p data-bbox="448 629 724 660">(Fehr & Caviness 1977)</p>	 <p data-bbox="975 533 1027 555">Flower</p>
<p data-bbox="568 779 608 810">R2</p> <p data-bbox="461 864 711 896"><u>Floración completa</u></p> <p data-bbox="256 927 919 999">Una flor abierta en uno de los dos nudos superiores del tallo principal, con hojas totalmente desarrolladas.</p> <p data-bbox="448 1025 724 1057">(Fehr & Caviness 1977)</p>	 <p data-bbox="967 994 1054 1016">Uppermost node counted</p> <p data-bbox="1023 1055 1110 1077">Indeterminate variety</p> <p data-bbox="1198 1055 1251 1077">Flower</p>
<p data-bbox="568 1205 608 1236">R3</p> <p data-bbox="416 1290 759 1321"><u>Inicio formación de vainas</u></p> <p data-bbox="269 1352 903 1460">Vaina de 5mm en uno de los cuatro nudos superiores del tallo principal con las hojas totalmente desarrolladas</p> <p data-bbox="285 1547 887 1619">http://cropwatch.unl.edu/deferring-first-soybean-irrigation-until-stage-r3</p>	
<p data-bbox="568 1702 608 1733">R4</p> <p data-bbox="344 1787 831 1818"><u>Vainas completamente desarrolladas</u></p> <p data-bbox="253 1850 919 1921">Vaina de 4cm en uno de los cuatro nudos superiores del tallo principal con las hojas totalmente desarrolladas.</p> <p data-bbox="472 1944 703 1975">Iowa State University.</p>	

R5

Inicio de formación de las semillas

Una semilla de 3mm en uno de los cuatro nudos superiores del tallo principal con las hojas totalmente desarrolladas.

http://agro.unc.edu.ar/~ceryol/documentos/soja/feno_soja.pdf



R6

Semilla completamente desarrollada

Una semilla verde que rellena la cavidad de una vaina en uno de los cuatro nudos superiores del tallo principal con las hojas totalmente desarrolladas.



Fotografía propia

R7

Inicio de maduración

Una vaina normal en cualquier nudo del tallo principal ha alcanzado su color de madurez.



Fotografía propia

R8

Maduración completa

El noventa y cinco por ciento de las vainas han alcanzado el color de maduración



Fotografía propia

Estrategias de producción determinantes del ciclo del cultivo de soja

Para una adecuada elección y manejo de cultivares de soja se considera fundamental contar con una apropiada caracterización del ambiente, porque el mismo condiciona el crecimiento y el rendimiento y en consecuencia determina cuáles son los grupos de madurez (GM) y el manejo de los mismos, que permitirán alcanzar las mayores productividades. A medida que mejora la calidad del ambiente el cultivo alcanza un mayor desarrollo vegetativo y es posible utilizar cultivares de ciclo más corto, para evitar el vuelco, y reducir la incidencia de problemas sanitarios. Las características ambientales se pueden dividir en abióticas (climáticas, edáficas) y bióticas (enfermedades, plagas) (Baigorri n.d.).

Entre las características más relevantes propias del cultivo, a tener en cuenta en el Cono Sur, se debe mencionar el GM. Debido a la respuesta fotoperiódica de la soja (planta de día corto), los cambios en latitud modifican la longitud del ciclo de cada cultivar, los que incrementan su ciclo a medida que se los cultiva en latitudes más altas. En nuestra región esto ocurre cuanto más al sur se los cultiva. Es decir que cada cultivar tiene una franja latitudinal en la que por su longitud de ciclo se lo considera como de ciclo medio; al norte de la misma se comporta como ciclo corto y al sur de esta como ciclo largo. Un error en la elección del GM produce pérdidas de rendimiento. Cuando se siembran cultivares de ciclo más corto que lo recomendado, los mismos reducen su crecimiento y su rendimiento. Si se siembran cultivares de ciclo más largo de lo recomendado, se retrasa demasiado el inicio de la fructificación, reduciendo la posibilidad de expresión de su potencialidad productiva, se incrementan los costos de control de enfermedades, plagas y malezas y aumenta el riesgo de ocurrencia de heladas que afecten el llenado de granos.

Respecto al momento de siembra, la fecha de siembra óptima de un cultivar es aquella que:

- Asegura un buen crecimiento evitando el vuelco.
- Ubica el período crítico del cultivo (llenado de granos) en un momento con menor ocurrencia de estrés hídrico y mayor disponibilidad de radiación solar y temperatura.
- Reduce la incidencia de enfermedades.
- Minimiza la probabilidad de ocurrencia de daños por helada.
- Ubica la cosecha en un momento, que por la distribución de las precipitaciones, tenga una baja probabilidad de sufrir demoras y afectar la calidad de semilla.

Es por estos argumentos que en la zona de estudio no se encuentran establecidos momentos principales para la siembra del cultivo de soja. Más bien pueden encontrarse lotes con este cultivo, en un continuo de fechas de siembra. Siendo posible observar a campo, lotes en diversidad de estadios fenológicos, y más aún con distinta duración de su ciclo.

Sensoramiento remoto

Es posible encontrar muchas definiciones de sensoramiento remoto, también nombrado como teledetección; dentro de éstas se define a la teledetección como la medición, o adquisición de información, de alguna propiedad de un objeto o fenómeno, por medio de un dispositivo de grabación que no está en contacto físico o íntimo con el objeto o fenómeno en estudio (Colwell et al. 1983). Los sensores remotos, generalmente a bordo de aviones o satélites que orbitan la Tierra, miden la energía o radiación electromagnética (REM) que es reflejada o emitida por los objetos (Chuvieco 2010). En especial el sensoramiento remoto satelital ha progresado tremendamente desde que Landsat 1 fue lanzado el 23 de Junio de 1972. A partir de entonces las mediciones por medio de la teledetección, han resultado en observaciones indispensables y vitales, para entender nuestro planeta a través del tiempo (Panda et al. 2015). La teledetección en comparación con otros métodos de recopilación de datos, es mucho más ventajosa ya que proporciona una visión general de los fenómenos de la Tierra, que permiten a los usuarios discernir patrones y relaciones que no son evidentes desde el suelo (Aronoff 2004). El sensoramiento remoto tradicional involucra dos procesos básicos: la adquisición de datos y su análisis. En la Figura 3 se ilustran estos procesos y su uso final en aplicaciones.

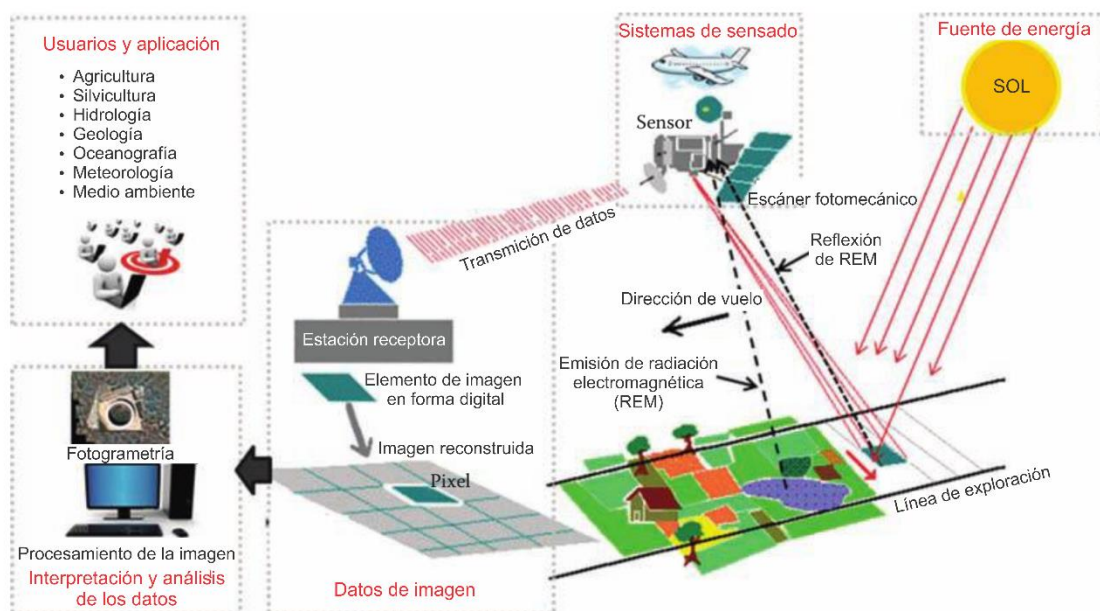


Figura 3. Recolección de los datos, procesamiento, análisis y uso final. Extraído de Panda et al. (2015).

Según Lillesand et al. (2004), existen elementos específicos involucrados en cada etapa del sensoramiento remoto, estos se resumen en la Tabla 6.

Tabla 6. Elementos y factores involucrados en la teledetección. Fuente Lillesand et al. (2004).

Adquisición de datos	Factores que afectan la recolección	Procesamiento y análisis
1. Fuente de energía	1. Posición solar	1. Interpretación por medio de hardware y software
2. Propagación de la energía por la atmósfera	2. Condiciones atmosféricas	2. Análisis con otros datos geoespaciales
3. Interacción con la superficie terrestre	3. Tiempo y meteorología	3. Aplicación de los datos – apoyo a la toma de decisiones
4. Transmisión de la energía por la atmósfera	4. Estación del año	
5. Sensor en plataforma	5. Condición de la superficie	
6. Datos y su formato resultante	6. Características del sensor	
	7. Posición del sensor	

La fuente habitual de datos en teledetección pasiva, es la medición de la radiación electromagnética reflejada o transmitida (REM) desde el sol a lo largo del espectro electromagnético (EEM) (Panda et al. 2015). En general, la teledetección pasiva consiste en la medición de la energía solar reflejada (o radiación emitida) por la superficie de la Tierra mediante sensores montados en plataformas aeronáuticas o espaciales, mientras que la teledetección activa implica energía sintética (no solar) emitida de forma activa al medio ambiente desde un satélite, una aeronave, o cualquier otra plataforma, para después registrar y almacenar las señales de retorno medidas (Schott 2007; Schowengerdt 2007). Una descripción grafica de sistemas de teledetección activa y pasiva, se realiza en la Figura 4.




Figura 4. Sistemas de teledetección activa, y pasiva con diferentes plataformas. Extraído de Panda et al. (2015).

Principios del espectro electromagnético en teledetección

La luz o el flujo radiante en forma de energía electromagnética, que incluye luz visible, infrarrojo, ondas de radio, térmicas, rayos ultravioletas, y rayos x, es la forma primaria de energía utilizada

en teledetección (Lillesand et al. 2004). De acuerdo con Murai (1993), la REM consta de cuatro características, tales como (1) la frecuencia/longitud de onda, (2) dirección de transmisión, (3) la amplitud, y (4) la polarización. Estas cuatro características son importantes para la teledetección ya que cada una corresponde a diversas propiedades. La longitud de onda/frecuencia se corresponde con el color de un objeto en la región visible, que está representado por una curva de característica única. La dirección de transmisión y la amplitud, correspondiente a la dirección de propagación y a la magnitud de las ondas, es influenciada por la ubicación y la forma espacial de los objetos. Finalmente, el plano de polarización, es decir, la orientación del campo eléctrico de la energía radiante, es influenciado por la forma geométrica de los objetos bajo investigación. Por consiguiente en base a las características espectrales de los objetos, la REM proporciona información detallada sobre los mismos. El EEM es dividido en varias regiones de longitudes de onda (frecuencia), como el sector de los rayos gamma (10^{-6} – 10^{-5} μm), de los rayos X (10^{-5} – 10^{-2} μm), las radiaciones UV (0.1–0.4 μm), la región visible (0.4–0.7 μm), la del infrarrojo (0.7– 10^3 μm), las microondas (10^3 – 10^6 μm), y la correspondiente a las ondas de radio ($>10^6$ μm) (Panda et al. 2015). La Figura 5 representa la longitud de onda de diferentes bandas, asociadas a sus respectivas regiones espectrales, junto con la denominación de la banda -asociada a sistemas de teledetección- que adquiere los datos en ese intervalo.

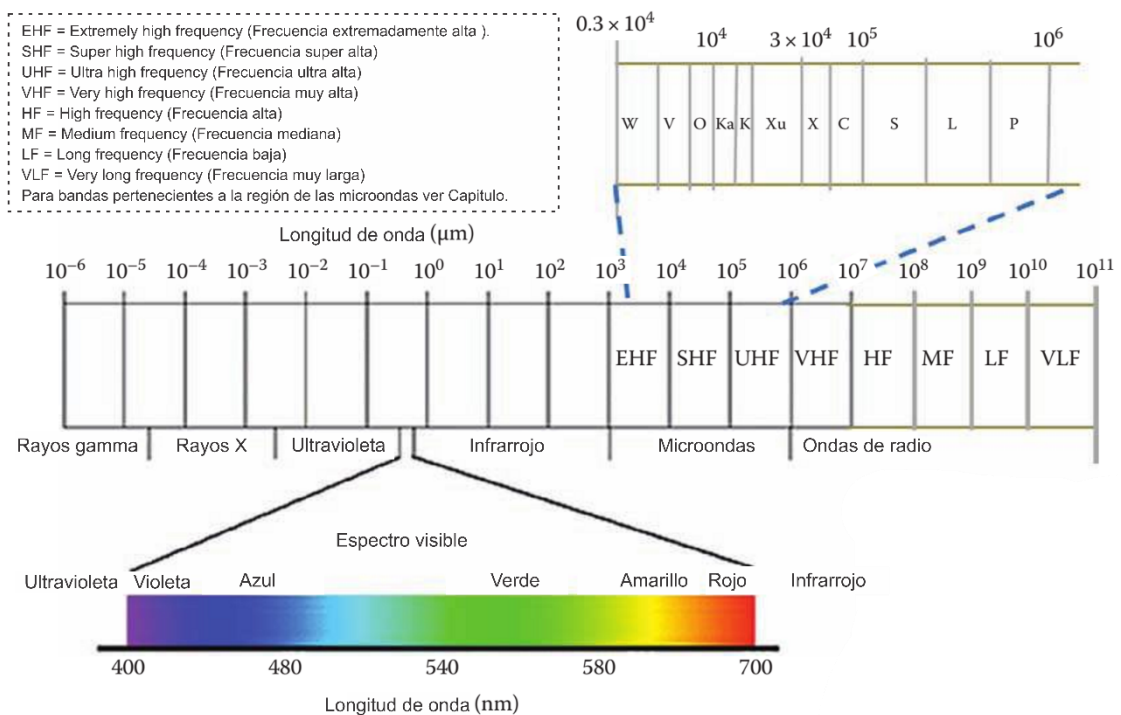


Figura 5. Espectro electromagnético sobre el cual los sistemas de teledetección están basados (Panda et al. 2015).

A pesar de que muchos objetos naturales tienen características comunes en sus curvas de reflectancia espectral, lo cual dificulta su identificación y separación, las diferencias sutiles y su varianza en el tiempo permiten su clasificación (Bowker et al. 1985). La Figura 6 muestra una típica curva de reflectancia para la vegetación fotosintéticamente activa. Esta parte del espectro electromagnético reflejado por la vegetación puede ser dividido en 3 regiones de acuerdo al factor más importante en el comportamiento de la reflectividad. Por debajo de los 0,7 μm , la

absorción es dominada por los pigmentos carotenoides (centrada a los 0,48 μm) y la clorofila *a* y *b*. Estas últimas poseen una doble absorción característica sobre la región del azul y el rojo (centradas a los 0,450 y 0,670 μm respectivamente) (Chappelle et al. 1992). El pico verde (centrado aproximadamente a los 0,56 μm) es la región del espectro visible correspondiente a la absorción débil. El fuerte aumento alrededor de los 0,7 μm (conocido como borde rojo) marca el cambio desde la absorción de la clorofila a la reflectancia celular. La reflectancia en el infrarrojo cercano desde los 0,7 a los 1,3 μm es dominada por la interfaz del espacio de aire de la pared celular y, en menor medida, por las discontinuidades en el índice de refracción de los constituyentes celulares (Gausman 1974). Más allá de los 1,3 μm , la reflectancia es primariamente controlada por el contenido de agua en las hojas. La mayor parte de las mencionadas regiones, son abarcadas por las bandas de varios sensores. Con respecto a la dinámica en el tiempo, durante el ciclo de crecimiento de la vegetación, la reflectancia disminuye en la longitud de onda visible y aumenta en las longitudes de onda del infrarrojo cercano hasta que el máximo desarrollo de la canopia es alcanzado. Entonces, con el inicio de la senescencia, la reflectancia en longitudes de onda del espectro visible aumenta, mientras la reflectancia en el infrarrojo cercano decrece, aunque relativamente a menores valores. De esta manera la reflectancia de la vegetación usualmente progresa desde un fondo gobernado por el suelo, a un pleno verdor, para luego retornar nuevamente al fondo. En este contexto el comportamiento temporal puede ser utilizado para separar cultivos (Badhwar et al. 1982).

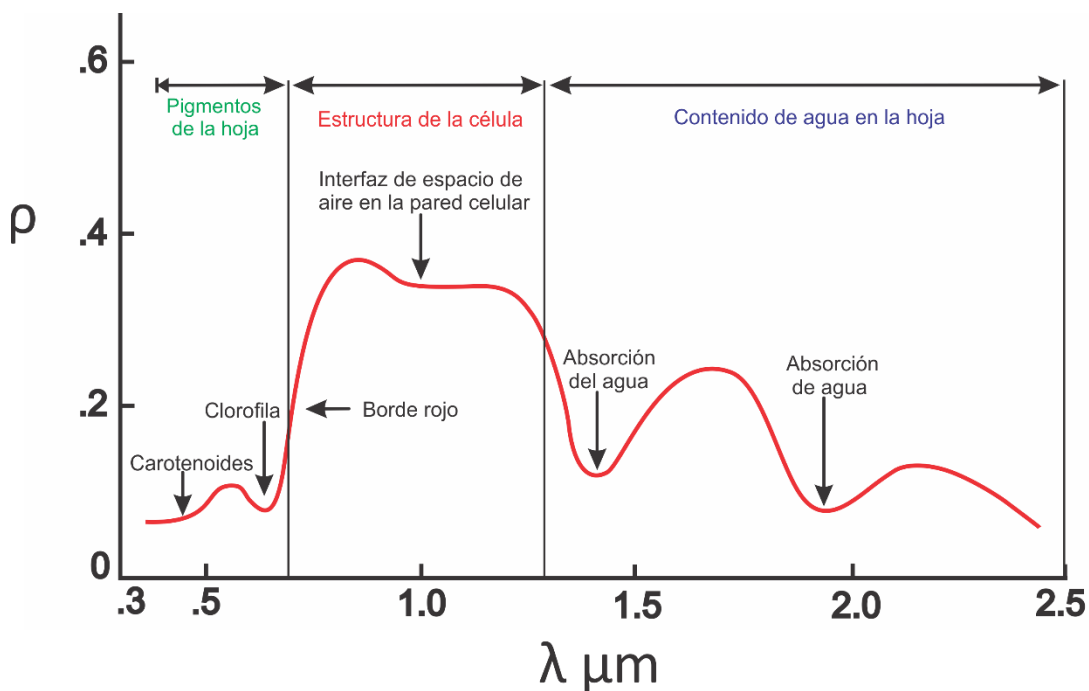


Figura 6. Curva de reflectancia típica de la vegetación, mostrando los factores dominantes que controlan la reflectancia de la hoja. Adaptado de Vane et al. (1982).

Sensores utilizados en la presente tesis

La teledetección desde satélite cuenta con numerosas aplicaciones, gracias a las ventajas que ofrece frente a otros medios de observación más convencionales, como la fotografía aérea o los trabajos de campo, aunque más que sustituirlos los complementa. Entre las ventajas de esta observación espacial, podemos destacar las siguientes: cobertura global y exhaustiva de la superficie terrestre, perspectiva panorámica, observación multiescala y no destructiva, información sobre regiones del espectro no visible, entre otras (Chuvienco 2010). En contraste con las plataformas aéreas, las plataformas satelitales son enormemente costosas y complejas.

El desarrollo y despliegue de sensores al igual que la carga útil de los satélites pueden tomar entre 5-10 años. Sin embargo, una vez que la plataforma satelital se encuentra en funcionamiento, los datos de los sensores espaciales suelen ser muy consistentes y permiten a los usuarios finales desarrollar aplicaciones robustas, tales como el análisis sobre el cambio de cobertura terrestre, en particular para grandes extensiones de la superficie de la Tierra. Por lo tanto, dependiendo de las resoluciones proporcionadas por los sensores a bordo, las plataformas de satélite ofrecen una amplia gama de escalas de mapeo. En la presente tesis se han utilizado dos tipos de sensores, que se clasifican en activos y pasivos, cuyas características se describen a continuación.

En sistemas activos una de las principales ventajas es la energía activa utilizada (microondas), la cual es independiente de la energía solar y es menos afectada por los componentes atmosféricos. Esto ofrece enormes ventajas para la teledetección sobre las regiones de ambientes tropicales, donde las nubes y la lluvia son fenómenos meteorológicos frecuentes, que interfieren con los sistemas tradicionales ópticos/pasivos. Por otra parte, los sensores activos no requieren de energía solar y por lo tanto pueden operar durante la noche. Además, estos sistemas tienen mejor capacidad para detectar los atributos de la vegetación y del suelo - dependientes del contenido de humedad-, lo que otorga un inmenso valor en diversas aplicaciones, incluyendo la hidrología, geología, glaciología, la silvicultura y la agricultura. Las desventajas incluyen inferiores características espectrales, procesamiento de datos complejo, volumen masivo de datos, y un mayor costo (Panda et al. 2015). En el presente estudio las imágenes de radar de apertura sintética que se utilizaron, proceden de la constelación italiana CosmoSky med (Covello et al. 2010).

Los sensores pasivos se limitan a recoger la energía electro-magnética procedente de las cubiertas terrestres, ya sea ésta reflejada de los rayos solares, o emitida en virtud de su propia temperatura (Chuvienco 2010). Al no poseer fuente de energía propia no pueden ser usados en horas nocturnas, con excepción de los sensores termales u ópticos de alta sensibilidad. Los sensores pasivos pueden clasificarse de forma amplia, en aquellos que operan en la región del visible - infrarrojo y los que operan en la región de las microondas. A su vez en función del procedimiento que emplean para recibir la radiación procedente de los objetos pueden ser divididos en; sensores fotográficos, óptico electrónicos, y antenas. Dentro del grupo de sensores pasivos, en la presente tesis se emplearon imágenes provenientes de los satélites Landsat 7 y 8 (United States Geological Survey n.d.).

Características de las imágenes

Una imagen digital es una matriz, definida por filas y columnas, constituida por píxeles, o elementos de la imagen tal como se muestra en la Figura 7. Cada píxel registra un valor numérico representativo del nivel de brillo o de la intensidad de la energía reflejada. Las imágenes producidas por diferentes sensores sobre sistemas satelitales presentan características únicas, relacionadas a las resoluciones: espacial, espectral, radiométrica y temporal.

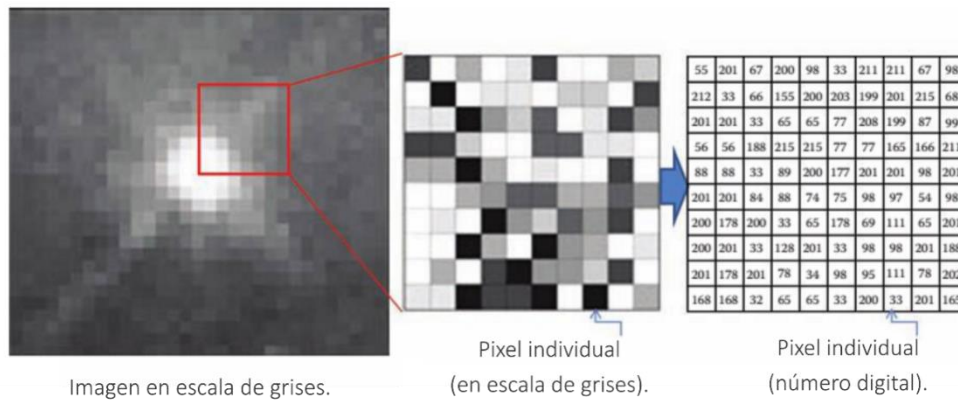


Figura 7. Configuración de una matriz mostrando el pixel (elemento de la imagen). Extraído de Panda et al. (2015).

La resolución espacial implica la unidad de superficie para la que el sensor registra la energía reflejada, proporcionando un único número digital (DN) o valor de brillo (véase la figura 7). Por ejemplo, un sensor del satélite Landsat 7, detecta un espacio de tierra que es de 30 x 30m (bandas visibles e infrarrojas). Por lo general, la resolución espacial de una imagen es igual a la distancia de muestreo en el suelo –Ground Sample Distance (GSD)-, que es el detalle discernible más pequeño de una imagen (Gonzalez & Woods 2002). Según Shaw & Burke (2003) el mejor desempeño en la detección es esperado cuando la GSD, es proporcional a la huella de los objetivos de interés. Por ejemplo, si la aplicación a desarrollar requiere de la observación de la cubierta terrestre mundial, las imágenes de baja resolución son entonces adecuadas. Por otro lado, si la aplicación requiere información detallada sobre la superficie terrestre, como en el estudio del estrés hídrico en un cultivo de maíz, las imágenes de alta resolución son ideales. Algunos sensores remotos proporcionan datos en dos o más resoluciones espaciales MODIS, Sistema de Observación de la Tierra (EOS-Terra), Landsat, y *Système Probatoire d’Observation de la Terre* (SPOT) son ejemplos de adquisición de imágenes basado en resolución espacial dual –usualmente la banda pancromática posee mejor resolución espacial que las correspondientes al escáner multiespectral-. En general, la resolución espacial puede ser clasificada en cinco grandes clases: 0,5-4,9 m (muy alta resolución), 5,0-9,9 m (alta resolución), 10,0 a 39,9 m (resolución media), 40,0 a 249,9 m (resolución moderada), y 250 m-1,5 km (baja resolución)(Panda et al. 2015).

El periodo de revisita del satélite (resolución temporal) hace referencia a la cantidad de tiempo que tarda el satélite en volver a tomar la misma imagen de una región de la Tierra (Panda et al. 2015), por ejemplo el satélite Landsat 8 tarda 16 días. Por lo tanto, la resolución temporal absoluta de un sistema de teledetección es equivalente al periodo de tiempo necesario para adquirir una imagen exacta de la misma zona y en el mismo ángulo de visión por segunda vez consecutiva. Esta capacidad de recolectar imágenes de una misma área de la superficie terrestre en diferentes períodos de tiempo es una de las características más importantes para la aplicación de los datos de teledetección. El factor de tiempo en imágenes, es importante cuando:

1. Existen nubes persistentes (a menudo en los trópicos)
2. Se estudian fenómenos de corta duración (siembra, cosecha, floración).
3. Se requieren múltiples comparaciones temporales (por ejemplo, la propagación de una enfermedad).
4. La apariencia cambiante de una característica en el tiempo, puede ser utilizada para distinguir objetos casi similares (sorgo / maíz).

Los sensores de satélite capturan la energía reflejada o emitida (en un rango de región espectral) de la superficie terrestre (en una unidad de superficie del suelo), esta energía se cuantifica en un DN, cuyo valor depende de la intensidad de la energía detectada. La resolución radiométrica describe la variedad (cuantitativa) de valores de brillo discretos perceptibles (Richards 2013). Cuando una imagen se adquiere en una película o por un sensor, su sensibilidad a la magnitud de la REM determina su resolución radiométrica. La resolución radiométrica de un sistema de sensado describe su capacidad para distinguir ligeras diferencias en energía. Cuanto mayor sea la resolución radiométrica de un sensor, más sensible es en la detección de pequeñas diferencias en la energía reflejada o emitida (Canada Center for Remote Sensing 2014). Con frecuencia, la resolución radiométrica se expresa en términos del número de dígitos binarios, o bits, necesarios para representar el rango de valores de brillo disponibles. Por ejemplo los datos con una resolución radiométrica de 8 bits tienen 256 niveles de brillo, mientras que los datos con resolución radiométrica de 12 bits tienen 4.096 niveles de brillo (Richards 2013).

Como se mencionó, los sensores satelitales miden la radiación electromagnética en diferentes porciones del espectro electromagnético (EEM). La resolución espectral es la capacidad del sensor para distinguir las características espectrales en componentes separados del EEM. También describe la capacidad de un sensor para distinguir intervalos de longitud de onda en el EEM. En general, la resolución espectral determina el número y extensión de las bandas que el sensor del satélite puede registrar. Así imágenes de mayor resolución espectral proporcionarán más información espectral en comparación con las de menor. La información espectral es particularmente útil en aplicaciones que tratan el mapeo, como así también el modelado de las propiedades biofísicas de los objetos, tales como la calidad del agua, vigor de plantas, y los nutrientes del suelo. Una de las ventajas de sensar separadamente regiones espectrales diferentes, se relaciona con la capacidad de combinar las bandas de diversas maneras para mejorar la información visual de la imagen. Estas combinaciones se implementan fácilmente utilizando distintos softwares, en los cuales se apilan por lo menos tres bandas de imágenes y se asignan los valores de los datos a los tres colores fundamentales (rojo, verde y azul), para crear imágenes compuestas. Cuando se posee datos de satélite con mayor resolución espectral, más características de la superficie de la Tierra pueden discernirse al realizar combinaciones de bandas que resultan en diferentes colores compuestos (Panda et al. 2015).

Realizada esta introducción, en la Tabla 7 se describen las características correspondientes a los sensores de los satélites utilizados en la presente tesis: Landsat 7, Landsat 8 y CosmoSkymed.

Tabla 7. Características de los productos satelitales utilizados en la presente tesis (Chander et al. 2009; Ariza 2013; Covello et al. 2010).
NIR: Infrarrojo cercano. SWIR: Infrarrojo de onda corta. TIRS: Sensor infrarrojo termal.

Característica	Landsat 7				Landsat 8				Cosmo-Skymed
Tipo de sensor	Pasivo				Pasivo				Activo
Resolución espacial	Dependiente de la banda				Dependiente de la banda				Dependiente del modo de adquisición (1-100m)
Resolución temporal	16 días				16 días				16 días
Resolución radiométrica	8 bit				12 bit				Dependiente del nivel de procesamiento
	banda	Región del espectro	Longitud de onda (micrómetros)	Dimensión del pixel cuadrado (m)	banda	Región del espectro	Longitud de onda (micrómetros)	Dimensión del pixel cuadrado (m)	
Resolución espectral	B1	Azul	0.45–0.52	30	B1	Ultra Azul	0.43–0.45	30	Banda X (microondas de 3cm)
	B2	Verde	0.52–0.61	30	B2	Azul	0.45–0.51	30	
	B3	Rojo	0.63–0.69	30	B3	Verde	0.53–0.59	30	
	B4	NIR	0.77–0.90	30	B4	Rojo	0.64–0.67	30	
	B5	SWIR-1	1.55–1.75	30	B5	NIR	0.85–0.88	30	
	B6	Termal	10.40–12.50	60	B6	SWIR -1	1.57–1.65	30	
	B7	SWIR-2	2.09–2.35	30	B7	SWIR -2	2.11–2.29	30	
	B8	Pancromático	0.52–0.90	15	B8	Pancromático	0.50–0.68	15	
					B9	Cirrus	1.36–1.38	30	
					B10	TIRS-1	10.6–11.19	100	
					B11	TIRS-2	11.5–12.51	100	

Capítulo 3

Revisión de algoritmos de clasificación de cultivos agrícolas a partir de imágenes satelitales

Introducción

La creciente disponibilidad de datos de bajo costo o gratuitos, como la proporcionada por Global Land Cover Facility (GLCF), la caída constante de los precios de hardware y software, así como un mejor conocimiento acerca de las posibilidades de aplicación de la tecnología de teledetección, proporcionan el impulso necesario para la evaluación del cambio de la cobertura de la tierra en el mundo en desarrollo (Otukey & Blaschke 2010). El uso combinado de la teledetección y sistemas de información geográfica (GIS) se están convirtiendo en herramientas esenciales para el mapeo de la cobertura del suelo, análisis y modelado de escenarios futuros (Geneletti & Gorte 2003). Siendo potencialmente una tecnología más eficiente -en términos de tiempo, detalle y costos- para la estimación de áreas de cultivadas (Nitze & Schulthess 2012). En este sentido el mapeo de la cobertura del suelo y su evaluación, es una de las áreas centrales de aplicación de los datos de sensores remotos (King 2010; Foody 2002). La cobertura terrestre es una variable fundamental, que impacta y se conecta con muchos aspectos del ser humano y el ambiente físico (Foody 2002). El cambio en la cobertura del suelo es considerado como la variable simple más importante que afecta la dinámica global de los sistemas ecológicos (Vitousek 1994). Una variedad de conjuntos de datos "Land use-land cover" (LULC) es necesaria para apoyar las crecientes y diversas demandas de la comunidad mundial de investigación en cambio ambiental (Cihlar 2000). Varios de los principales programas de investigación y documentos (National Aeronautics and Space Administration 2002; National Research Council (NRC) 2001) han identificado al desarrollo de mejores y actualizados productos LULC a escala regional-global, como una prioridad de investigación (Wardlow & Egbert 2008). Esta información puede ser empleada en estudios agrícolas, control de subvenciones, o como información auxiliar para la predicción de la producción (Nitze & Schulthess 2012).

Para obtener efectivamente información fiable a partir de datos de satélite, es esencial disponer de adecuadas técnicas de clasificación. En su capítulo sobre el concepto de mapa preciso, (Maling 1989) acertadamente reconoce que los mapas son generalizaciones deliberadas de la realidad, y que en todo proceso de producción de encuestas y mapas, inevitablemente se introducen errores. El usuario de los mapas de cobertura de suelo tiene que saber cuan exacto es el producto, con el fin de utilizar los datos de manera eficiente. Así mismo existen varias limitaciones en relación a la clasificación sobre áreas agrícolas: en primer lugar las relacionadas a las labores culturales inherentes a cada lote (método de labranza, fecha de siembra, técnica riego, fertilización); en segundo lugar las similitudes en la reflectancia entre cultivos, como así también las variaciones espaciales y espectrales dentro del lote, y finalmente la necesidad de contar con métodos simples y fáciles manejar e interpretar (Tatsumi et al. 2015).

Una serie de métodos-técnicas de clasificación han sido desarrollados en las últimas décadas, y una revisión de estos algoritmos puede ser encontrado en Lu & Weng (2007). Los clasificadores pueden categorizarse ya sea como comunes o avanzados. Algunos de los algoritmos de

clasificación comunes (convencionales) incluyen al K-Means, ISODATA, Clasificador de Máxima Verosimilitud (MLC) y la distancia mínima a las medias (Erdas Inc 1999; Mather 2011), mientras que los algoritmos de clasificación avanzados comprenden a las redes neuronales artificiales (ANN), los árboles de decisión, las máquinas de soporte vectorial, y el análisis de imágenes basado en objetos (Kim et al. 2003; Keuchel et al. 2003; Blaschke 2006; Yang et al. 2011). Estos algoritmos avanzados, al ser independientes de los supuestos de distribución de datos, pueden mejorar la precisión y efectividad del proceso de clasificación (Tatsumi et al. 2015; Bocco et al. 2007; Cutler et al. 2007).

A pesar del importante papel que juega la información de la cobertura de la tierra en el seguimiento y la comprensión del medio ambiente, nuestro conocimiento del estado de la superficie del suelo y su dinámica, especialmente en las zonas rurales de Argentina, todavía es limitado. El estudio de coberturas agrícolas con algoritmos convencionales fue efectuado satisfactoriamente en la región central de Argentina (Murthy et al. 2003; Badhwar 1987; Guerschman et al. 2003; Willington et al. 2013), mas recientemente (Bocco et al. 2007; Bocco et al. 2012; Bocco et al. 2014; Gutiérrez Angonese & Grau 2014) realizaron estudios de mapeo de suelos utilizando técnicas derivadas del enfoque de machine learning. Sin embargo análisis más complejos, automatizables y aplicables a macro regiones aún están faltando.

Enfoques de Procesamiento

Algoritmos de clasificación derivados del aprendizaje automático

¿Qué entendemos por aprendizaje?

El término **APRENDIZAJE** puede ser definido como:

“Cualquier proceso que modifica un sistema, para mejorar de manera más o menos irreversible, la posterior realización de una misma tarea” (Langley & Simon 1981)

Sin embargo el aprendizaje es un concepto bastante resbaladizo. Hay muchas cosas que cambian su comportamiento de manera de poder desempeñarse mejor en el futuro, pero ello no quiere decir que efectivamente, han aprendido. En el lenguaje cotidiano, a menudo utilizamos la palabra "entrenamiento" para denotar una especie de aprendizaje sin sentido. Pero el aprendizaje es diferente. El aprendizaje implica pensamiento. El aprendizaje implica propósito. Algo que aprende tiene que hacerlo intencionalmente. Aprender sin propósito es simplemente entrenamiento (Witten & Frank 2005).

Con esta introducción al concepto de aprendizaje, se puede definir preliminarmente al "aprendizaje automático" como "un campo de estudio que da a las computadoras la capacidad de aprender sin ser programadas de forma explícita" (Simon 2013). El aprendizaje automático explora el estudio y construcción de algoritmos que pueden aprender y hacer predicciones en los datos (Kohavi & Provost 1998). Tales algoritmos operan mediante la construcción de un modelo, por ejemplo de entradas con el fin de hacer predicciones o decisiones basadas en datos, en lugar de seguir estrictamente las instrucciones estáticas de un programa. En los próximos apartados se describen dos algoritmos de clasificación pertenecientes al campo del aprendizaje automático, los cuales son utilizados en la presente tesis.

Random Forest

Random Forest (RF) es un algoritmo consistente en una colección de clasificadores con estructura de árbol, donde cada árbol emite un voto único para la clase más popular de la entrada utilizada (Breiman 2001). En un clasificador RF, cada árbol es entrenado por un subconjunto aleatorio de la base de datos original, y alrededor de un tercio de los elementos son dejados afuera del conjunto de entrenamiento. Este último sub-conjunto se conoce como out-of-bag (OOB). Estos elementos OOB, que son dejados de lado durante el entrenamiento del árbol, son finalmente clasificados por el mismo para evaluar su exactitud (Zhong et al. 2014). La exactitud de todos los elementos OOB, o exactitud OOB, es una estimación no sesgada de la clasificación en general, por lo cual no es necesario realizar una validación cruzada o una prueba de conjunto separado (Breiman 2001).

Un clasificador RF requiere de la definición de solo dos parámetros para la generación del modelo de predicción: el número de árboles de clasificación deseados (k) y el número de variables de predicción (m) a usar en cada nodo para hacer crecer el árbol. Cuando el valor de k supera un determinado umbral, dependiente del problema en estudio, la precisión global experimenta aumentos poco significativos y sin problemas de sobre entrenamiento (Breiman 2001).

Entre las características deseables del clasificador RF podemos nombrar (Breiman 2001):

- I. La precisión es tan buena como la alcanzada por Adaboost⁴ y algunas veces mejor.
- II. Es relativamente robusto a valores atípicos y al ruido.
- III. Es más rápido que bagging o boosting⁵.
- IV. Brinda información útil sobre estimaciones internas del error, la fuerza, correlación e importancia de variables.
- V. Es simple y fácilmente paralelizado.
- VI. Es capaz de tomar numerosas variables de entrada y ejecutar clasificaciones rápidas, sin ser severamente afectado por el "curse of dimensionality" (Rodríguez-Galiano, Chicaolmo, et al. 2012).

Lo que diferencia a RF de otros métodos derivados del aprendizaje automático son dos características. La primera de ellas es la medida de importancia de variables usada en RF, la cual no sufre las deficiencias de los métodos de selección de variables tradicionales. Analizando datos sobre plantas invasivas, presencia de líquenes y sitios de nidificación, Cutler et al. (2007) observaron que las variables identificadas por RF como las más importantes, coincidían con las expectativas ecológicas basadas en la literatura. La segunda característica que distingue a RF de sus competidores, es la matriz de análisis que puede realizar. La mayoría de estos involucra las proximidades – medidas de proximidad entre puntos de datos – automáticamente producidas por RF. Las proximidades pueden ser utilizadas para imputar puntos de datos faltantes, como entrada a los métodos multivariados tradicionales basados en las distancias y las matrices de covarianza, tales como el análisis de conglomerados y el escalamiento multidimensional y para facilitar representaciones gráficas de los resultados de la clasificación.

Al igual que con otros métodos altamente computacionales, las relaciones entre las variables predictoras y los valores predichos producidos por RF no tienen simples representaciones gráficas como una fórmula (ej. regresión logística), o un gráfico pictórico (ej. arboles de

⁴ Una descripción metodológica de Adaboost puede realizarse en Freund & Schapire (1996)

⁵ La metodología de Bagging y Boosting es desarrollada en Breiman (1996) y Freund (1995) respectivamente.

clasificación) que caracterice la función de clasificación entera. Esta falta de simpleza en la representación puede dificultar su interpretación. Los gráficos de dependencia parcial para una o dos variables predictoras a la vez, pueden ser construidos para cualquier clasificador de “caja negra” (Hastie et al. 2001). Si la función de la clasificación es dominada por variables individuales e interacciones de bajo orden, entonces estos gráficos pueden ser una efectiva herramienta para visualizar los resultados de la clasificación (figura 8), pero no son útiles para caracterizar o interpretar las interacciones de orden superior (Cutler et al. 2007).




Figura 8. Grafico bivariado de dependencia parcial para *Urtica dioica*. Variables: *DistRoad*, distancia a la carretera más cercana (m). *DistTrail*, distancia a la carretera o camino más cercano (m). Extraído de Cutler et al. (2007)

En el trabajo de Rodríguez-Galiano et al. (2012) sobre el territorio mediterráneo Español, se evaluó la precisión de clasificación usando los algoritmos Random Forest y MLC. Para ambos se utilizaron como variables de entrada distintas medidas texturales a partir de dos imágenes Landsat 5. Para la clasificación de las clases agrícolas, las cuales tienen un marcado comportamiento estacional, la utilización de variables texturales tuvo una importancia excepcional. En términos generales el uso de RF sobre los datos espectrales y las variables texturales óptimas, tuvo un desempeño 31% mayor en comparación a MLC usando solo datos espectrales.

Más recientemente Zhong et al. (2014) en un estudio que abarcaba 5 años, utilizaron el algoritmo RF para clasificar lotes cultivados con soja y maíz en el Condado de Doniphan, Kansas (EEUU). El algoritmo era entrenado con datos de una campaña agrícola, de modo de ser aplicado y evaluado sobre las 5 campañas en estudio. En total fueron definidas 25 combinaciones para los pares de datos de entrenamiento y evaluación. Como datos de entrada se utilizaron varios conjuntos de variables (datos de reflectancia, métricas fenológicas, índices de vegetación, temperatura acumulada). Cuando en la clasificación se utilizaban como entradas datos del mismo año, todos los conjuntos de entrada alcanzaban precisiones mayores al 85%. No obstante cuando el clasificador era entrenado con datos que no correspondían al año de la clasificación, solo el uso de métricas fenológicas producían precisiones aceptables (>82%). El mencionado estudio concluyó que las métricas fenológicas son menos afectadas por los errores de medición y los vacíos temporales entre imágenes, ya que estas se obtuvieron de series de datos temporales en lugar de observaciones de un solo momento. En el mismo ámbito de trabajo, Long et al. (2013) realizando clasificaciones sobre áreas agrícolas con el algoritmo RF, alcanzaron precisiones más altas al utilizar modelos multi-temporales en comparación a los basados en datos de un solo momento. Esto último es válido tanto para enfoques de clasificación a nivel de pixel como el orientado a objetos (O-O). El hecho que el algoritmo RF crea múltiples caminos para alcanzar una correcta clasificación, permitió unificar lotes del mismo cultivo sembrados en distintas fechas.

Support Vector Machine

Las máquinas de soporte vectorial o máquinas de vectores de soporte (SVM por sus siglas en inglés) se caracterizan por su enfoque no paramétrico de clasificación. Aunque originalmente fueron diseñadas para problemas de clasificación binarios, el enfoque se puede extender para resolver problemas de múltiples clases (Löw et al. 2013). Las SVM implementan la siguiente idea: Los datos de entrenamiento originales, son transformados a un espacio de mayor dimensión, donde un hiperplano de separación óptima puede ser construido (Vapnik 2000). Con una transformación (no lineal) apropiada, este hiperplano de separación óptima siempre existe. Las SVM identifican este hiperplano haciendo uso de vectores de soporte -vectores de entrenamiento "esenciales"- y márgenes -definidos por los vectores de soporte- (Waldner et al. 2015). Este hiperplano de separación óptima -OSH, por sus siglas en inglés- es ajustado a las características espaciales de los datos de entrenamiento -por ejemplo dos clases-, entonces los márgenes entre el OSH y las muestras de entrenamiento más cercanas son maximizados (Löw et al. 2013). Las SVM se enfocan en las muestras de entrenamiento que se encuentran más cercanas a los bordes de las distribuciones de clase (Mathur & Foody 2008).

El OSH puede ser definido como $f(x) = wx + b$, donde el parámetro w determina la orientación del hiperplano en el espacio, y b define el margen de error la distancia del hiperplano desde el origen (Figura 9). Una explicación matemática detallada de SVM se puede encontrar en Vapnik (2000). Como se mencionó anteriormente cuando no es posible definir un OSH haciendo uso de ecuaciones lineales, los datos pueden ser esquematizados en un espacio de mayor dimensión a través de algún mapeador no lineal. Su efecto es el de desparramar los puntos en análisis, de tal forma que el ajuste del hiperplano lineal es facilitado (Mathur & Foody 2008).




Figura 9. Las dos clases son separadas por un margen de $d_1 + d_2$, por medio de dos hiperplanos H_1 y H_2 con un hiperplano óptimo de separación en medio de los dos. Los vectores de soporte de las dos clases son mostradas en círculos sobre los planos H_1 y H_2 (Extraído de Mathur & Foody (2008) y Hofmann (2006))

La precisión de las SVM puede disminuir si los datos de entrada no son normalizados (Ali & Smith-Miles 2006). Esto ocurre, por ejemplo, cuando se trabaja con atributos en escalas originales grandes, mientras que el espacio de los datos se encuentra normalizado a una escala común $[0, 1]$, la solución puede resultar sesgada (Löw et al. 2013).

A pesar de que sufren de ciertas desventajas tales como el sobreajuste y dificultad en la selección de los parámetros para la construcción del hiperplano, las SVM están siendo particularmente requeridas sobre todo en el campo de la teledetección. Esto debido a su

capacidad de generalizar bien, incluso con limitadas muestras de entrenamiento - una restricción común para las aplicaciones de teledetección (Mountrakis et al. 2011) - y una alta dimensional de los datos (Pal & Mather 2005).

El uso de Kernels⁶ en datos no separables linealmente

En los problemas donde el conjunto de datos no es separable linealmente, el desafío es encontrar una transformación $T: R^N \rightarrow R^M$, (con $M > N$) de tal forma que el conjunto R^M sea separable con un modelo lineal. Es decir, los conjuntos de datos con características no lineales deben ser reescritos en un mayor espacio dimensional, en el cual una SVM puede encontrar un hiperplano de separación lineal con el máximo margen. Sin embargo trabajar con conjuntos de datos en dimensiones superiores puede incrementar las dificultades computacionales, hasta hacerlos no manipulables (Muller et al. 2001).

Para superar esta limitación, en lugar de mapear los conjuntos de datos a través de una función de transformación y calcular el producto interno, es posible realizarlo en una sola operación, dejando la transformación de forma implícita. De hecho no es necesario conocer la función de transformación, todo lo que necesitamos saber es cómo calcular el producto interno modificado. Los métodos que permiten calcular este "producto interno modificado", dejando de lado los costos computacionales, se conocen como funciones kernel (Jordan & Thibaux 2004).

Un Kernel es una función K , tal que para todo x, z en el espacio dimensional X cumple

$$K(x, z) = \langle \varphi(x) \cdot \varphi(z) \rangle, \quad (1)$$

Donde K es una transformación desde X a un espacio de características F (Cristianini & Shawe-Taylor 2000).

Debido a que cada Kernel tiene un cierto grado de variabilidad, en general no existe de forma predeterminada una mejor opción para problemas específicos. En la práctica no se hace otra cosa que experimentar con diferentes Kernels y ajustar sus parámetros, a fin de minimizar el error en un conjunto de prueba (Hofmann 2006). En la Tabla 8, se presentan las funciones Kernels utilizadas para clasificaciones con SVM en la presente tesis.

Tabla 8. Descripción de productos internos de Kernels. Adaptado de Hofmann (2006).

Tipo de Kernel	Producto interno del Kernel $K(x, x_i), i = 1, 2, \dots, N$
Radial basis function (RBF)	$K(x, x_i) = e^{(-\gamma \ x - x_i\ ^2)}, \gamma > 0.$
Polinomial	$K(x, x_i) = (x^T x_i + r)^d.$
Sigmoideo	$K(x, x_i) = \tanh(x^T x_i + r)$

Donde γ, r y d son parametros de las funciones Kernel

⁶ Si bien existe una traducción al castellano para el término "kernel", en adelante se continuara utilizando el nombre en inglés en correspondencia con la bibliografía básica.

Enfoque de análisis orientado a objetos.

Cuando se trabaja con datos en alta resolución espacial, los métodos tradicionales de clasificación a nivel de píxel no son muy adecuados. Esto debido a que la información es de gran tamaño y detallada (Blaschke & Strobl 2001; Hofmann 2001). En esta clase de problemas está siendo usado el enfoque de clasificación orientado a objetos. Este no solo toma en cuenta la información inherente a cada píxel, sino también los patrones locales de la imagen representados por grupos de píxeles vecinos, con el fin de generar segmentos (Van der Sande et al. 2003). El término segmentación de una imagen se refiere, en su sentido más amplio, al proceso de dividir una imagen digital en múltiples regiones. Ciertamente, todos los algoritmos de agrupamiento caen dentro de esta categoría. Sin embargo el término se utiliza de una manera más restrictiva, es decir, como una referencia a la partición de píxeles, no sólo por la similitud espectral, sino también por la proximidad espacial (Canty 2014). La segmentación ofrece la posibilidad de un perfeccionamiento de la clasificación sobre la base de las características de los segmentos individuales -no necesariamente relacionadas a las intensidades de los píxeles-, tales como la forma, el tamaño y la proximidad a otros objetos (Blaschke 2005; Benz et al. 2004). En general se usa el término “*clasificación basada en objetos*” (Canty 2014).

Las técnicas de segmentación desarrolladas en las últimas décadas se pueden dividir en tres categorías (Ballard & Brown 1982): (1) búsqueda de bordes (Roberts 1963); (2) región de crecimiento (Tilton 1989); y (3) segmentación basada en el conocimiento o en mapas (Janssen 1994). Ya que para el desarrollo del presente trabajo no se disponía de información vectorial del área de estudio, y se pretendió realizar un primer ensayo de estas metodologías por medio de métodos simples, se decidió utilizar un algoritmo perteneciente a la segunda categoría: región de crecimiento. El algoritmo utilizado fue *Meanshift*, el cual al ser un método no supervisado puede ser empleado sin conllevar en incrementos significativos del tiempo de procesamiento, además de ser de bajo costo en términos computacionales (Comaniciu & Meer 2002). En el trabajo de Formaggio et al. (2012), se utilizó el algoritmo *Meanshift* para detectar y delimitar áreas con cobertura verde, degradadas y suelo desnudo, generando como resultado regiones uniformes, que podían salvaguardar las desviaciones producidas por las líneas de cultivo, sombras y texturas menores.

Región de crecimiento:

La idea conceptual del método es que la información semántica importante que se requiere para interpretar una imagen no está representada en los píxeles individuales, sino en los objetos significativos de la imagen y sus relaciones mutuas, es decir el contexto. El método de región de crecimiento parte de objetos de una unidad de píxel para generar otros de mayor dimensión (número de píxeles). En muchos pasos subsiguientes los objetos más pequeños de la imagen se fusionan en otros más grandes. La decisión de unificación se basa en criterios de homogeneidad locales, que describen la similitud de objetos adyacentes en términos de tamaño, distancia, textura, similitud espectral y forma (Baatz & Schäpe 2000). Los umbrales definidos por el usuario se utilizan de forma interactiva para decidir si los objetos se fusionan en objetos más grandes. El procedimiento de crecimiento se detiene cuando las fusiones obedeciendo el criterio del usuario ya no son posibles.

El algoritmo “meanshift”

Meanshift es un algoritmo de región de crecimiento no paramétrico. Es decir que no se hacen suposiciones con respecto a la densidad de probabilidad de las observaciones que son agrupadas. El algoritmo particiona los píxeles en conjuntos de N -dimensiones (N -características), asociando los píxeles de cada conjunto con un máximo local en la densidad de probabilidad estimada, llamado modo. Para cada píxel, el modo asociado se determina mediante la definición de una (hiper) esfera de radio $r_{espectral}$ centrada en el píxel, a partir de la cual se calcula la media del conjunto de píxeles dentro de la esfera. Entonces el centro de la esfera se desplaza a esa

media. Este proceso continúa hasta que se logra la convergencia, es decir, hasta que el desplazamiento de la media es menor que algún umbral. En cada iteración, la esfera se mueve a una región de mayor densidad de probabilidad hasta que se alcanza un modo. Los píxeles colindantes son asignados a ese modo.

Para limitarnos al sentido estricto de la segmentación de imágenes, adicionalmente se debe incluir la posición espacial de los píxeles. Para lograr esto solo es necesario extender el espacio de características incluyendo esta dimensión. Entonces, adicionalmente a $r_{espectral}$, un radio espacial $r_{espacial}$ es fijado para determinar el desplazamiento medio. Después de una normalización apropiada de las distancias espectrales y espaciales, por ejemplo mediante el reescalamiento de las intensidades de los píxeles, el procedimiento de “mean shift” se lleva a cabo en el espacio de característica espectral-espacial, dimensional $N + 2$ concatenado, utilizando una hiper-esfera de radio $r = r_{espacial}$ (Canty 2014).

Capítulo 4

Mapeo de cultivos agrícolas en base a datos espectrales y de verdad de terreno contemporáneos.

Como se hizo referencia en el capítulo 1, el mapeo de cultivos por medio de técnicas de teledetección posee ventajas de alta eficiencia y bajo costo, comparado a métodos basados en encuestas, lo cual hace factible la generación de cartografía en la mayoría de los casos. Los métodos basados en encuestas a terreno aún poseen mayores precisiones de mapeo en comparación a los basados en la detección remota, por lo tanto su sustitución depende de la tasa de cambio de uso de la tierra en la región bajo estudio. Si el cambio de uso del suelo que se produce en el intervalo en el que se realizan dos encuestas consecutivas es considerable, el enfoque basado en teledetección con capacidad de mapeo de mayor frecuencia es necesario. De lo contrario, los datos de encuestas son suficientes para la mayoría de las aplicaciones. En el presente trabajo de tesis fue necesario crear datos de referencia a campo para la campaña agrícola 2012-2013, para lo cual en una primera etapa se compara el desempeño de diferentes algoritmos de clasificación.

En el presente capítulo se describe el uso práctico de la teledetección en el mapeo de cultivos, así como la explicación y la evaluación de algoritmos de clasificación experimentados. Estos algoritmos propuestos deberían ser pasibles de implementar en la mayoría de las circunstancias, con un mínimo tiempo de procesamiento. El enfoque de la clasificación de Máxima Verosimilitud (MLC) es probado en primera instancia. MLC es un enfoque de clasificación supervisada ampliamente utilizado, con ventajas tales como: i) estar disponible en la mayoría de entornos de análisis de datos de teledetección y su aplicación se desarrolla sin esfuerzos adicionales, ii) ser un método relativamente robusto poco probable de producir resultados anormales o caer en el sobre ajuste, y iii) como clasificador supervisado paramétrico, MLC genera salidas predecibles y comprensibles (Zhong 2012). En una segunda instancia se explora el potencial de los algoritmos pertenecientes al campo del aprendizaje automático: Support Vector Machine (SVM) y Random Forest (RF).

Para algunas aplicaciones de planificación de políticas agropecuarias a corto plazo, la capacidad de identificación del tipo de cultivo en tiempo real o casi en tiempo real es deseable, ya que, por ejemplo permitiría proporcionar una estimación actual de producción y decidir sobre consecuentes subvenciones. Por lo tanto se requieren algoritmos y procedimientos que nos permitan mapear tipos de cultivo en los momentos más cercanos al inicio de la campaña agrícola como sea posible. Atendiendo a estos requerimientos, los objetivos desarrollados en este capítulo fueron: i) **determinar la aplicabilidad de los datos registrados por el sensor Landsat 8;** ii) **Comparar el desempeño de los algoritmos de clasificación de Maxima Verosimilitud, Máquinas de Soporte Vectorial y de Arboles de decisión con muestras aleatorias,** y iii) **explorar el ajuste de los parámetros, y los efectos de la naturaleza y número de clases a entrar en los modelos, para diferenciar cubiertas agrícolas por familia taxonómica.**

Materiales y métodos

Procesamiento de los datos de entrada

Datos satelitales

Una imagen Landsat 8 del área de estudio (path/row: 229/82) cuya fecha de adquisición se corresponde con el momento en el cual los cultivos se encontraban en etapas reproductivas de su ciclo (23 de marzo 2016), fue descargada del sitio web del Servicio Geológico de los Estados Unidos (<http://earthexplorer.usgs.gov/>). El tiempo era bueno para el periodo de adquisición de datos Landsat, las nubes estaban casi ausentes y no se presentaba smog en la atmósfera.

El procesamiento de los datos del sensor OLI incluyó el reescalado a valores de reflectancia en el techo de la atmosfera (TOA), usando para ello los coeficientes radiométricos provistos en el archivo de metadato MTL.txt. La siguiente ecuación fue usada para convertir los ND (niveles digitales) obtenidos por el sensor OLI a valores de reflectancia (Ariza 2013):

$$P\lambda = M_p Q_{cal} + A_p \quad (2)$$

Donde:

$P\lambda$: Es el valor de reflectancia planetaria, sin corrección por ángulo solar.

M_p : Es el factor multiplicativo de escalado específico por banda obtenido del metadato ("REFLECTANCE_MULT_BAND_x", donde x es el número de la banda).

A_p : Es el factor aditivo de escalado específico por banda obtenido del metadato ("REFLECTANCE_ADD_BAND_x", donde x es el número de la banda).

Q_{cal} : Es el producto estándar cuantificado y calibrado para valores de pixel (DN).

Paralelamente se realizó el cálculo del producto NDVI (Normalized Difference Vegetation Index). Como variables de entrada a los modelos de clasificación se utilizaron las bandas 2, 3, 4, 5, 6 y 7 del sensor OLI.

Datos de referencia a terreno

La base de datos para el presente trabajo corresponde a la información de uso del suelo en el área de estudio durante la campaña agrícola 2015/16. En la mencionada campaña se realizó un relevamiento a 70 lotes de uso agrícola. El mismo fue realizado con fecha 13 de marzo de 2016, registrándose cultivo presente, cultivo antecesor (mediante análisis del rastrojo remanente), estado sanitario y estadio fenológico del cultivo. Sobre esta última característica es importante realizar un análisis exhaustivo, ya que son datos claves que permiten diferenciar la estrategia en cuanto a la fecha de siembra, elegida por el productor. Poder diferenciar tipos de cobertura según la ubicación temporal del ciclo del cultivo, permite diseñar una correcta metodología de clasificación de áreas dedicadas a la agricultura. De la totalidad de registros aproximadamente la mitad se utilizó en el entrenamiento de los algoritmos y la otra mitad en la etapa de validación. A continuación se describen los estadios fenológicos en el cual se encontraban los cultivos para la indicada fecha de muestreo.

Estado de los cultivos al momento del muestreo a campo

Los lotes correspondientes al cultivo de maíz, se encontraban en etapas reproductivas de su ciclo fenológico. Se identificaron tres grandes grupos, que abarcaban:

- 7 lotes de siembra temprana, los cuales se encontraban en R4, R5 y R6.
- 4 lotes de siembra intermedia, en estado de grano lechoso (R3).
- 11 lotes de siembra tardía (mes de enero), se encontraban finalizando su etapa vegetativa (VT), hasta el estadio de ampolla (R2).

Con respecto a los lotes sembrados con cultivo de Soja, se diferenciaban parcelas en todas las fases de su etapa reproductiva. Al ser un cultivo muy plástico, se consideraron inicialmente los siguientes grupos:

- 6 lotes en estados avanzados del ciclo, inicio de maduración (R7 y R8).
- 4 lotes en estados intermedios, formación de semillas (R4 - R6).
- 4 lotes en estadios reproductivos iniciales (R1- R3).

En el caso de los lotes con cultivo de Sorgo se pudieron distinguir 2 estadios reproductivos

- 2 lotes en estadio de grano duro.
- 6 lotes en estado de floración-grano pastoso.

Finalmente en el caso del cultivo de maní, es imperativo reiterar que la superficie sembrada en el área de estudio es mínima. En la recorrida visual se registraron tres lotes, los cuales se encontraban en etapa de formación de semilla (R5) y semilla completa (R6). En la Figura 10 se exponen instantáneas de los cultivos en las mencionadas etapas fenológicas.



Maíz emergencia de estigmas



Maíz grano dentado



Maíz madurez fisiológica



Soja formación de semillas



Soja semilla completa



Soja inicio de maduración



Sorgo floración-grano pastoso



Sorgo grano duro



Maní inicio formación semilla



Maní semilla completa

Figura 10. Estadios fenológicos de los cultivos al momento de la toma de datos a campo.

Clasificación no supervisada utilizando el algoritmo K-means

Preliminarmente para la definición de las diferentes clases de cobertura agrícola se realizó un análisis exploratorio por medio de clasificaciones no supervisadas. Para ello se utilizó el algoritmo K-means compilado en la caja de herramientas de Orfeo (QGIS 2.14). Como datos de entrada se utilizó en una primera instancia el producto NDVI, con el fin de discriminar los tipos de cobertura homogénea, por su índice de vegetación. En una segunda instancia se utilizaron las seis bandas de reflectancia. Realizando combinaciones de los parámetros “clases” e “iteraciones” se corrieron los modelos descritos en la Tabla 9:

Tabla 9. Descripción de los modelos de clasificación no supervisada ejecutados

Modelo	Datos de entrada	Clases	Iteraciones
1	Imagen NDVI (23 marzo)	10	5
2	Imagen NDVI (23 marzo)	20	5
3	Imagen NDVI (23 marzo)	20	10
4	Imagen NDVI (23 marzo)	20	20
5	Imagen NDVI (23 marzo)	30	5
6	Imagen NDVI (23 marzo)	30	10
7	Imagen NDVI (23 marzo)	30	20
8	Bandas 2-7 (23 marzo)	10	5
9	Bandas 2-7 (23 marzo)	20	5

Posteriormente se realizó una confrontación visual entre la verdad a terreno y los grupos formados en cada ejecución del algoritmo. También se consideró la homogeneidad alcanzada dentro de los lotes. Del análisis de las imágenes resultantes se observa que utilizando el producto NDVI al variar el número de iteraciones del algoritmo desde 5 a 20 no se advierten apreciables diferencias en los resultados. Se podría decir que los modelos alcanzan la convergencia con un número de 5 iteraciones. En contraste el parámetro número de clases influye notoriamente en la homogeneidad del tipo de cobertura dentro de cada lote. Las pruebas mostraron que 10 clases, abarcaban la heterogeneidad general de coberturas, manteniendo cierta homogeneidad dentro de cada lote. En la clasificación de cultivos estivales (Wardlow et al. 2007; Arvor et al. 2011), comprobaron que el NDVI puede capturar variaciones más sutiles entre cultivos en momentos de inicio de la campaña agrícola, debido a las diferencias en las fechas de siembra. En la discriminación de coberturas agrícolas mejores resultados se obtienen al utilizar como entrada las bandas de reflectancia espectral (Peña & Brenning 2015). En general se advierte que los lotes que presentan homogeneidad en el tipo de clase, son aquellos en los cuales el cultivo se encuentra en inicio de la etapa reproductiva (floración, llenado de granos). Una comparación de estos resultados puede observarse en la Figura 11.




Figura 11. Imagen de verdad de terreno y las resultantes de clasificaciones no supervisadas⁷

A partir de estos resultados y con la información de referencia a campo, se definieron las clases de coberturas a introducir en los posteriores modelos de clasificación supervisada. Se consideraron las siguientes, con los respectivos códigos:

- | | |
|--------------------------------|-----------------------------|
| C1: Soja temprana (R7 a R8). | C9: Sorgo |
| C2: Soja intermedia (R4 a R6). | C10: Maní |
| C3: Soja tardía (R1 a R3). | C12: "Pozo" de infiltración |
| C4: Maíz extra temprano (R6). | C13: Agua |
| C5: Maíz temprano (R4 y R5). | C14: Urbano |
| C6: Maíz intermedio (R3). | C15: Ruta asfaltada |
| C7: Maíz tardío (R1 y R2). | |
| C8: Maíz extra tardío (VT). | |

⁷ El número de tipos de cobertura que arroja cada modelo dependió de sus parámetros asociados, por lo que no fue posible establecer una clave de color general, para las pruebas realizadas.

Finalmente cada unidad de parcela o tipo de cobertura fue representado por un polígono, en los atributos del mismo se incluyó la información sobre tipo de uso de la tierra. Para el muestreo de cada clase se tuvo en cuenta lo enunciado por la bibliografía existente, la cual sugiere un mínimo de 10- 30p casos por clase para entrenamiento, donde p representa el número de bandas a usar (Foody et al. 2006). Por consiguiente se decidió tomar muestras de cada clase con un mínimo de 450 píxeles. En el caso de las parcelas de uso agrícola, cada muestra fue tomada teniendo en cuenta un buffer de distancia negativa (90m) con respecto a los límites del lote, con el fin de eliminar las influencias de píxeles mixtos.

Metodología de clasificación supervisada

Siguiendo con lo descrito en el capítulo introductorio, se decidió comparar el desempeño del algoritmo de clasificación de máxima verosimilitud, contra otros derivados del enfoque de machine learning; SVM y RF. Como datos de entrada, se ingresaron las bandas 2, 3, 4, 5, 6 y 7. Con respecto al ajuste de los parámetros de cada algoritmo, se siguió las recomendaciones de Nitze & Schulthess (2012); Waldner et al. (2015a); Long et al. (2013); Ok et al. (2012); y Tatsumi et al. (2015).

Las corridas con el algoritmo de Máxima Verosimilitud se realizaron con el software de procesamiento ENVI 4.8. Para cada modelo se varió las clases de entrada como verdad de terreno, y el parámetro “Umbral de probabilidad”. En los primeros resultados se advirtió que a pesar de reducir el valor del parámetro a 0.01, la gran mayoría de los píxeles quedaban sin clasificar (Figura 12). Por estos motivos no se hizo uso del mismo.

Las posteriores pruebas de clasificación se realizaron variando únicamente el número de clases a entrar a los modelos, quedando determinada la configuración que se presenta en la Tabla 10. Los modelos MLC_1, MLC_2 y MLC_3 se realizaron a modo exploratorio, a fin de analizar el comportamiento de los algoritmos cuando se ingresaban clases no agrícolas. Pruebas similares fueron realizadas en las clasificaciones con los algoritmos RF y SVM.

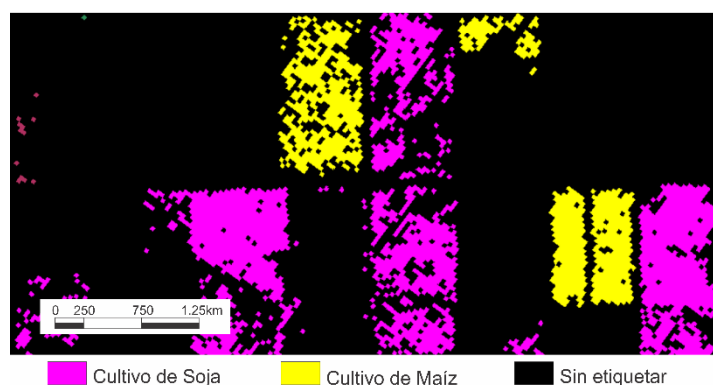


Figura 12. Clasificación con algoritmo ML, umbral de probabilidad = 0.01

Tabla 10. Clases utilizadas en los modelos de clasificación con el algoritmo de Máxima Verosimilitud (MLC).

Modelo	Clases
MLC_1	Todas
MLC_2	Sin C13
MLC_3	Sin C12
MLC_4	Sin C12, C13
MLC_5	Solo de C1 a C10 (Cultivos anuales)
MLC_6	Solo de C1 a C8 (≠ estadios soja y maíz)
MLC_7	Solo por soja y maíz.

En las corridas realizadas con el algoritmo RF se ingresaron como datos de entrada el mismo conjunto de bandas que las utilizadas con MLC, y del mismo modo se varió los grupos de clases de entrenamiento. Esta vez se hizo uso de la rutina de clasificación RF compilada en la caja de herramientas de Orfeo, presente en el software QGIS 2.14. Adicionalmente se ajustaron los siguientes parámetros asociados al mencionado algoritmo de clasificación:

- I. Relación entre las muestras de validación y entrenamiento (V/T)
- II. Máxima profundidad del árbol (DT)
- III. Número mínimo de muestras en cada nodo (MS/N)
- IV. Tamaño de la muestra de características aleatoriamente seleccionada para cada nodo del árbol (SF/N).
- V. Número máximo de árboles a usar (MT)
- VI. Precisión requerida (Out of bag error)

Los modelos corridos poseían la configuración que se describe en la Tabla 11.

Tabla 11. Clases y parámetros utilizados en los modelos de clasificación con el algoritmo RF

Modelo	Clases	V/T	DT	MS/N	SF/N	MT	OOBE
RF_1	Todas	0.5	5	10	0	100	0.01
RF_2	Todas	0.3	10	10	0	100	0.01
RF_3	Sin 12	0.3	10	10	0	100	0.01
RF_4	Sin C12, C13	0.3	8	5	2	100	0.01
RF_5	Solo de C1 a C10 (Cultivos anuales)	0.3	8	5	2	100	0.01
RF_6	Solo de C1 a C8 (≠ estadios soja y maíz)	0.3	8	5	2	100	0.01
RF_7	Solo por soja y maíz	0.3	8	5	2	100	0.01

Finalmente para la realización de las pruebas con el algoritmo Support Vector Machine se hizo uso de la librería *libsvm*, desarrollada por Chang & Lin (2001). La misma está implementada en la interfaz gráfica de la caja de herramientas de Orfeo, presente en el software QGIS 2.14. *libsvm* realiza pruebas de validación cruzada y de modo automático encuentra el par óptimo de los valores de penalidad C y del parámetro γ , necesarios para su ejecución. Adicionalmente se ajustaron los siguientes parámetros asociados al algoritmo de clasificación:

- I. Relación entre tamaño de muestras de validación y entrenamiento (V/T)
- II. Tipo de kernel svm (KT)

A los fines de comparación con otros trabajos realizados en el mismo ámbito de estudio (Nitze & Schulthess 2012; Waldner et al. 2015), la relación V/T se fijó en el orden del 30%. Respecto al tipo de Kernel a usar, los estudios enfatizan el buen desempeño de RBF para problemas de clasificación de áreas agrícolas. Sin embargo cuando se logró una clasificación óptima, en acuerdo a la naturaleza de las clases de entrenamiento ingresadas al modelo, se decidió probar y visualizar los efectos que tienen los kernel de tipo “Sigmoideo” y “Polinomial”. Finalmente los modelos corridos utilizaban como datos de entrada el mismo conjunto de datos empleado con los algoritmos anteriores y detentaban la configuración que se presenta en la Tabla 12.

Tabla 12. Clases y parámetros utilizados en los modelos de clasificación con el algoritmo SVM

Modelo	Clases	KT
svm_2	Todas	RBF
svm_3	Sin 12	RBF
svm_4	Sin C12, C13	RBF
svm_5	Solo de C1 a C10 (Cultivos anuales).	RBF
svm_5a	Solo de C1 a C10 (Cultivos anuales).	Sig
svm_6	Solo de C1 a C8 (≠ estadios soja y maíz).	RBF
svm_7	Solo por soja y maíz	RBF
svm_8	Solo por soja y maíz	Poli

Validación

Con el fin de determinar la precisión de los mapas resultantes se procedió al cómputo de una matriz de confusión, utilizando como datos de validación la información derivada del relevamiento de los 70 lotes agrícolas de la campaña 2015 - 2016. Se calcularon los estadísticos Precisión Global (PG) y estadístico Kappa (κ) (Foody 2002). El coeficiente Kappa (κ) computa el acuerdo entre la imagen clasificada y la verdad de terreno, debido únicamente a la exactitud de la clasificación, suprimiendo el acuerdo que cabría esperar simplemente por azar. En Monserud & Leemans (1992) se propuso una escala para la interpretación del valor de dicho coeficiente donde valores menores a 0,40 se clasifican como pobres, 0,40-0,55 suficientes, 0,55-0,70 buenos, 0,70-0,85 muy buenos y mayores a 0,85 excelentes.

Resultados y discusión

Clasificación supervisada utilizando algoritmo de Máxima Verosimilitud

En la Tabla 13 se muestran los valores de los índices Kappa y las precisiones globales (en porcentaje) para los modelos MLC_4, MLC_5, MLC_6 y MLC_7, obtenidos al realizar la validación de los mapas mediante matrices de confusión (Apéndice A). Solo se exponen los resultados de estos cuatro modelos, ya que son los que incluyen a las clases agrícolas predominantes; éstas ocupan el 99% del área sembrada (Ministerio de Agroindustria de la Nación n.d.).

Tabla 13. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con MLC

Modelo	Índice Kappa (κ)	Precisión Global (%)
MLC_4	0,66	69,36
MLC_5	0,94	94,87
MLC_6	0,99	99,21
MLC_7	0,92	96,29

Al realizar las clasificaciones con el algoritmo MLC, sobresale en primer lugar la simplicidad y sencillez de su ejecución, así mismo su bajo costo computacional, el cual permite apreciar resultados casi instantáneos. De manera general se observa un muy buen desempeño del algoritmo clasificador en el mapeo de cubiertas exclusivamente agrícolas, lo cual concuerda con los resultados obtenidos en anteriores estudios sobre la misma área geográfica (Willington et al. 2013; Nolasco et al. 2016). En este tipo de estudios, y en particular en el área de trabajo, las amplias dimensiones de los lotes agrícolas posibilita la obtención de grandes conjuntos de píxeles representativos de cada clase, necesarios para un buen entrenamiento del algoritmo. Recientemente en otras regiones del globo, Jia et al. (2014) utilizaron imágenes Landsat 8 para mapear las macro clases “bosque”, “cultivos”, “suelo desnudo” entre otras, y alcanzaron una precisión global del 90% al usar el algoritmo MLC. En Yang et al. (2011), para el sur de Texas (Estados Unidos), se utilizaron imágenes del satélite SPOT 5 en el mapeo de cultivos de verano (maíz, algodón, sorgo, caña de azúcar) y suelo no cultivado, obteniendo con el algoritmo MLC una precisión global del 91%, concluyendo que es posible clasificar imágenes correspondientes a grandes áreas.

En el presente trabajo para el modelo MLC_6 las precisiones alcanzan el 99 por ciento con un índice κ de 0.99. Este excelente comportamiento puede relacionarse al trabajo de campo previo, en el cual se relevaron lotes de maíz y soja en sus diversos estadios de crecimiento. Esto permitió la construcción de clases puras, para los conjuntos de entrenamiento y validación. Sobre los errores en los mapas temáticos Tso & Mather (2009) afirman que pueden no deberse a la fiabilidad del clasificador, sino ser el resultado de una mala localización de algunos elementos de los datos de prueba o de una identificación defectuosa de los atributos de los datos muestreados. En este sentido es un gran desafío recolectar muestras representativas de la totalidad de las clases de una amplia área geográfica, por lo cual para mejorar las precisiones de clasificación Yang et al. (2011) recomiendan dividir el área en sub regiones a fin de realizar la clasificación por separado basándose en las firmas derivadas de esa sub región. Trabajando también en la pampa argentina y con cultivos similares, Guerschman et al. (2003) concluyeron

que la capacidad de discriminar entre las clases de coberturas de cultivos agrícolas está estrechamente relacionada con sus patrones fenológicos. Por ende clases de cultivos que posean similares patrones son a menudo mal clasificados. Este hecho fue identificado ya en los primeros estudios de mapeo realizados en la pampa Argentina, Badhwar (1987) encontró dificultades en la separación de las clases maíz y sorgo, especies pertenecientes a la misma familia botánica y de estructura morfológica similar. Estas afirmaciones corroboran la necesidad de un riguroso trabajo de campo y posteriormente, a gabinete, la determinación de clases de entrenamiento puras. No obstante, pueden siempre existir errores en la discriminación debidos a la variabilidad causada por la heterogeneidad del suelo dentro de un lote, situaciones de estrés, meteorológicas, plagas o malezas, lo cual debe ser tenido en cuenta al momento de planificar el muestreo. A diferencia de lo postulado por Guerschman et al. (2003), quienes expresan que el número de categorías tiene una relación inversa con las precisiones logradas, en el presente trabajo las mejores precisiones se alcanzaron cuando se utilizaron clases desagregadas en grupos que se limitaban a un estadio específico del ciclo de cada cultivo (MLC_6).

En este punto es necesario indagar en el efecto de la diferencia de 10 días entre la fecha de muestreo a campo y la de adquisición de datos satelitales. En un primer lugar, aunque se disponía de una imagen Landsat 7 temporalmente más próxima al momento de muestreo a terreno, los datos faltantes por el fallo SLC, sumado a la menor resolución radiométrica de este sensor, indujo a que se utilice finalmente la imagen del sensor Landsat 8. En segundo lugar se puede suponer que en ese lapso de tiempo se produzca una translación de un estadio fenológico al siguiente, en los cultivos de los lotes muestreados. No obstante en climas templados, la duración de los estadios fenológicos puede extenderse. En el presente estudio al momento del muestreo a campo (fines de verano) la temperatura ambiente estaba en descenso. Para el estadio de antesis (VT) en maíz, este puede prolongarse por más de dos semanas (Ritchie & Hanway 1982). En promedio cada etapa reproductiva del cultivo del maíz, dura alrededor de 10 días (Endicott et al. 2015). Para el caso del cultivo de soja, los periodos del ciclo del cultivo considerados en las clases analizadas, poseen una duración mínima de 10 días (Fehr & Caviness 1977). Por último se debe recordar que para la fecha de muestreo todos los estadios fenológicos presentes fueron abarcados en alguna de las clases de cobertura propuestas. Por lo que se podría considerar un leve error de corrimiento de una clase al siguiente estadio fenológico, pero no de aparición de estadios nuevos.

Siguiendo con el análisis de las precisiones logradas con los distintos modelos, cuando se incluyeron cultivos por medio de una única clase (MLC_5), o se fusionaron las muestras de los diferentes estadios de un cultivo en un solo grupo (MLC_7), las precisiones logradas fueron menores. En el área de estudio, para las clases sorgo y maní, no fue posible armar grupos por sus respectivos estadios fenológicos, debido al escaso número de lotes, que abarcan solo el 5% del área sembrada (Bolsa de cereales de Córdoba 2016).

Los resultados aquí presentados respaldan la conveniencia del algoritmo de Máxima Verosimilitud en el mapeo de cultivos agrícolas; el cual logra excelentes resultados en la discriminación de cultivos por sus respectivos estadios fenológicos, utilizando una única imagen de fin de temporada. Es imperioso resaltar que para alcanzar estos excelentes índices de precisión, es necesario realizar previamente un riguroso muestreo a campo y posterior organización de los datos a gabinete.

En lo que respecta a los modelos que incluían clases agrícolas y no agrícolas (MLC_1, MLC_2, MLC_3 y MLC_4), los mapas resultantes evidenciaban un comportamiento invasivo de las clases

no agrícolas, sobre las cubiertas de cultivos, esto puede deberse a una mayor variabilidad en los tipos de cobertura no agrícolas. En la corrida ML_1 la clase camino de tierra “ingresa” erróneamente dentro de lotes de clase maíz y soja. En ML_2 y ML_3 se distingue el mismo comportamiento con los tipos de uso de suelo ruta asfaltada y urbano respectivamente. En ML_4 las clases ruta asfaltada y urbano “ingresan” a algunos lotes de clase maíz intermedio y soja intermedia. Con respecto a los modelos puramente agrícolas, la mixtura de píxeles que se producen dentro de los lotes corresponde a clases que representan los diversos estados fenológicos de un mismo cultivo. Este comportamiento puede observarse en la Figura 14, para MLC_5 y MLC_6. En la Figura 13 se expone un recorte de la imagen Landsat 8 composición color real sobre el área de estudio, con fecha de adquisición 23 de marzo de 2016, el mismo se utilizará en adelante para realizar comparaciones visuales de los mapas resultantes. En esta última figura se encuentran señalados diversos lotes de cultivos, con el correspondiente código de clase definido en el apartado “Clasificación no supervisada utilizando el algoritmo K-means”. Estos códigos de clase de cobertura, son utilizados en adelante para los modelos de clasificación evaluados.




Figura 13. Recorte escena Landsat 8 del 23/03 sobre el área de estudio, composición color real. Se señalan lotes de cultivo con su correspondiente código de clase de cobertura.




Figura 14. Recortes de los mapas resultantes con los modelos MLC_5 y MLC_6.

Clasificación supervisada utilizando algoritmo Random Forest

En la Tabla 14 se exponen los valores de los índices Kappa y las precisiones globales (en porcentaje) para los modelos RF_4, RF_5, RF_6 y RF_7, obtenidos al realizar la validación de los mapas mediante matrices de confusión (Apéndice A). Como se expresó en el apartado anterior solo se exponen los resultados de estos cuatro modelos, ya que son los que incluyen a las clases agrícolas predominantes.

Tabla 14. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con RF

Modelo	Índice Kappa (κ)	Precisión Global (%)
RF_4	0,75	77,41
RF_5	0,74	76,78
RF_6	0,71	74,93
RF_7	0,88	94,37

Cuando se analizan las clasificaciones realizadas empleando el algoritmo Random Forest el aspecto que en primer lugar sobresale es la habilidad del método para mantener una separabilidad relativa cuando se ingresa la totalidad de las clases, hecho que se tornó dificultoso al usar MLC. Cuando se trabaja con clases soja y maíz desagregadas por su estadio fenológico es decir los modelos RF_5 y RF_6 (figuras 16 y 17 respectivamente), se aprecia un aumento en las precisiones logradas si son incluidas las clases sorgo y maní al modelo (RF_5). Sin embargo en este último se detectan fracciones de lotes de la clase soja tardía, mal clasificados como maní (Figura 16). Esta confusión podría deberse a la similitud en su reflectancia espectral (Schultz et al. 2015), esto se puede comprobarse al comparar sus firmas espectrales (Figura 15).

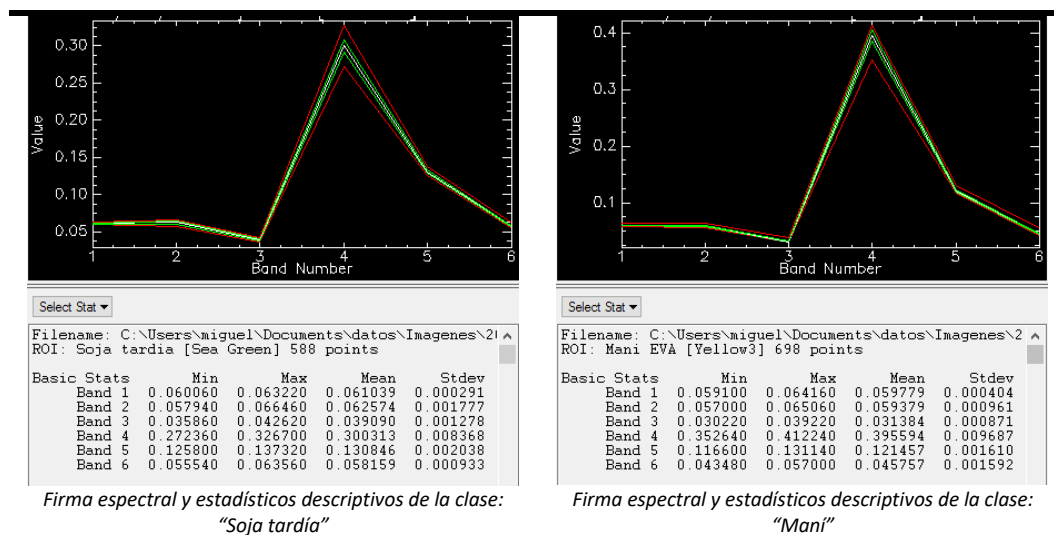


Figura 15. Firmas espectrales de las clases soja extra tardía y maní

Notablemente cuando se incluyen adicionalmente las clases ruta asfaltada y urbano (RF_4) las precisiones globales son sutilmente mayores (Figura 18). Estos resultados sugieren que la introducción de múltiples clases al problema de clasificación, permite al algoritmo la construcción de vías de clasificación más certeras. En la revisión bibliográfica realizada no se encontraron trabajos que indaguen el efecto de la cantidad y diversidad de clases sobre las

precisiones de los modelos de clasificación. Este tópico se plantea como una futura línea de investigación. En el modelo RF_7 el cual realiza una clasificación solo por especies soja o maíz (Figura 19) se aprecian los mejores índices que validan la misma. En este modelo los diferentes conjuntos de entrenamiento tanto para las especies soja y maíz en sus diversos estadios de crecimiento fueron unidos en las clases soja y maíz respectivamente, por lo cual el número de pixeles de entrenamiento por clase aumento considerablemente. En el trabajo de Tatsumi et al. (2015) se infiere que cuanto más se incrementan los datos de entrenamiento, mayor es la precisión del clasificador, de forma paralela hay menos necesidad de ajustar los parámetros del algoritmo RF. Por otro lado Camps-Valls et al. (2003) señalan que muchos métodos de discriminación incluidos los derivados del aprendizaje automático, a menudo son más precisos y eficientes cuando trabajan solamente con dos clases. Cabe señalar que cuando los resultados de la clasificación por el modelo RF_6, son unidos por su respectiva especie (es decir soja o maíz) y se recalculan los estadísticos de validación, se logran valores de κ y PG del 0,83 y 91,68% respectivamente, valores inferiores a los alcanzados por el modelo RF_7. Este comportamiento puede relacionarse a lo encontrado por Rodriguez-Galiano et al. (2012) quienes trabajando con datos multitemporales de Landsat 5 en la provincia de Granada, España, observaron que el error respecto al modelo calibrado, superaba el 5 %, con disminuciones mayores al 70% del conjunto de datos de entrenamiento. Este comportamiento evidencia que RF es sensible a la reducción del conjunto de entrenamiento.

Para el condado de Roosevelt, EEUU, trabajando con datos Landsat de fin de temporada, y las clases cereal, legumbres y otras, Long et al. (2013) alcanzaron valores de índice Kappa y precisiones globales de 0,68 y 81,7% respectivamente. Ok et al. (2012) realizaron clasificaciones en el área geográfica de la planicie de Karacabey (Turquía) utilizando una imagen SPOT 5 de mediados de temporada y las clases trigo, remolacha azucarera, arroz, maíz y tomate, logrando con el algoritmo RF valores de índice Kappa de 0,70 y precisión global de 76,15%. Estos últimos valores se asemejan a los obtenidos por el presente trabajo para el modelo RF_5, el cual incluye de manera semejante los cultivos más representativos del área de estudio. En el condado de Kansas, EEUU Zhong et al. (2014) realizaron mapas de cultivos de soja y maíz para en cinco campañas agrícolas, utilizando el algoritmo RF. Sus resultados fueron próximos al 90 % de PG, sugiriendo que los datos de campo del mismo año en que se realiza la clasificación son eficientes en el mapeo de lotes agrícolas con soja y maíz.

Con respecto a los modelos que incluían las clases agrícolas y más de una clase no agrícola, como se mencionó anteriormente, no se advirtió una mezcla grosera entre clases, como en el caso de los modelos que usaban el algoritmo clasificador de Máxima Verosimilitud. En el modelo RF_1 en el cual incluyó la totalidad de las clases bajo estudio, y la mayoría de los parámetros quedaron con su valor por defecto, se logró relativamente una buena separación entre clases.




Figura 16. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_5




Figura 17. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_6




Figura 18. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_4




Figura 19. Recorte escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo RF_7

En la posterior corrida (RF_2) se modificaron los valores de los parámetros “V/T” y “DT”. Para el parámetro V/T se adoptó 0.3, valor recomendado en la bibliografía consultada (Ok et al. 2012; Zhong et al. 2014; Tatsumi et al. 2015). Con respecto al parámetro DT, un valor bajo probablemente conduzca a un sub-ajuste, por el contrario un valor alto conduce al sobreajuste (OTB Team 2016). El valor óptimo se puede obtener usando validación cruzada u otros métodos adecuados. Para el modelo RF_2 se realizó una prueba con DT=10. En la imagen resultante se verificó la presencia de las clases sorgo y pozos de infiltración esta última ingresando a áreas cultivadas, principalmente con la especie soja.

En base a estos resultados se prosiguió con pruebas en las cuales se limitó el análisis a las clases más importantes en términos agronómicos. Por otro lado se reajustaron los parámetros del algoritmo RF. Se observó que la profundidad óptima para el problema de clasificación en estudio se situaba alrededor de 8, el número mínimo de muestras en cada nodo en 5 y el tamaño de muestras de características aleatoriamente seleccionadas, en un valor de 2. Estas modificaciones en el valor de los parámetros se mantuvieron constantes en la ejecución del modelo RF_4, RF_5, RF_6 y RF_7.

Clasificación supervisada utilizando el algoritmo Support Vector Machine

En la Tabla 15 se exponen los valores de los índices Kappa y las precisiones globales (en porcentaje) para los modelos svm 4, 5, 6, y 7, obtenidos al realizar la validación de los mapas mediante matrices de confusión (Apéndice A). Al igual que en la corrida con el algoritmo RF, se exponen los resultados de los modelos que incluyen predominantemente clases agrícolas.

Tabla 15. Valores de los estadísticos de evaluación para los mapas agrícolas realizados con SVM

Modelo	Índice Kappa (κ)	Precisión Global (%)
svm_4	0,85	86,44
svm_5	0,81	82,82
svm_6	0,92	92,88
svm_7	0,92	95,85

Cuando se analizan los resultados de la validación de los mapas realizados con el algoritmo SVM, sobresale en primer lugar la capacidad del algoritmo para mantener buenos índices de precisión, con los diversos grupos de clases de entrenamiento-validación. Estos buenos valores en los índices pueden relacionarse con la capacidad del algoritmo SVM para detectar y superar las bandas ruidosas, sumado al hecho del gran impacto de la optimización de los parámetros C y γ en la precisión de la clasificación, el cual permite sortear el sobre entrenamiento y una pobre generalización (Foody & Mathur 2004). Al igual que lo ocurrido en las corridas con el algoritmo RF, las precisiones de la clasificación aumentan cuando al modelo que incluye estrictamente clases agrícolas (svm_5) se le incorpora las clases urbano y camino (svm_4). Sin embargo a diferencia de lo ocurrido en RF y de manera semejante a la prueba con el algoritmo MLC, la precisión del mapa resultante también se incrementa, en relación al modelo svm_5, al analizar únicamente las clases soja y maíz en sus diferentes estadios fenológicos (svm_6). Cuando el objetivo es generar mapas de superficies dedicadas a los cultivos de soja y maíz, sin diferenciar por época de siembra, los resultados muestran que se obtienen mejores resultados si al modelo de clasificación se ingresan las clases correspondientes a los estadios fenológicos de cada cultivo, y luego se agrupan los pixeles correspondientes a cada especie. Esta estrategia alcanza valores de κ y PG del 1 y 100% respectivamente. En la mayoría de las aplicaciones, el éxito del aprendizaje automático está fuertemente afectado por la calidad de los datos (información redundante, ruidosa o poco confiable), en este sentido el trabajo realizado previamente en la determinación de las clases por estadio fenológico, pudo haber eliminado la mayoría de los valores atípicos, y de esta forma evitar el sobre entrenamiento, permitiendo alcanzar un excelente desempeño en la fase de prueba (Camps-Valls et al. 2004). En las Figuras 20, 21, 22 y 23 se exponen recortes de los mapas resultantes para los modelos svm 4, 5, 6 y 7 respectivamente.

Usando datos espectrales de una sola fecha sobre una región agrícola de Inglaterra del este Foody & Mathur (2004) mapearon sitios cultivados con trigo, remolacha azucarera, zanahoria, cebada, pasto y papas, utilizando el algoritmo clasificador SVM, logrando precisiones globales del 93%. Trabajando con múltiples clases (agrícolas, forestales, urbana y agua) en la región sur de España Rodríguez-Galiano & Chica-Rivas (2012) alcanzaron precisiones globales del 92% con un índice Kappa de 0,91 al usar el algoritmo SVM. A partir de datos espectrales en la región del rojo e infrarrojo Mathur & Foody (2008) realizaron mapeos de suelos discriminando por clases

agrícolas y no agrícolas en el sur-oeste de India, obteniendo con SVM precisiones del 92%. Utilizando datos Landsat 7 Pal & Mather (2005) mapearon cultivos agrícolas en el este de Inglaterra utilizando, al igual que en el presente trabajo la librería *libsvm*, obteniendo una precisión global e índice Kappa del 88% y 0,87 respectivamente. Estos últimos autores resaltan la capacidad de SVM para alcanzar buenas precisiones, aún con conjuntos de datos de entrenamiento pequeños. Sin embargo la sensibilidad de la precisión de las clasificaciones con SVM respecto al tamaño del conjunto de entrenamiento, indica la necesidad de que este conjunto incluya los casos periféricos, que producen vectores de soporte adecuados (Foody & Mathur 2004). Con los recaudos presentados, los citados trabajos respaldan en general el buen desempeño del algoritmo SVM, para el mapeo de la cobertura de suelos.

En lo que respecta a los modelos que incluían la totalidad de las clases (svm_2), se evidenció un comportamiento invasivo de la clase urbano sobre los lotes agrícolas, semejante a lo observado al utilizar el algoritmo RF. Aunque al igual que en la corrida con este último algoritmo sobresale la capacidad de SVM para lograr una buena discriminación de las múltiples clases en relación a MLC. En la corrida del modelo svm_5 se evidencia algunos lotes de soja tardía fueron clasificados como maní, del mismo modo que lo ocurrido al utilizar el algoritmo RF.




Figura 20. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_4




Figura 21. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_5




Figura 22. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_6

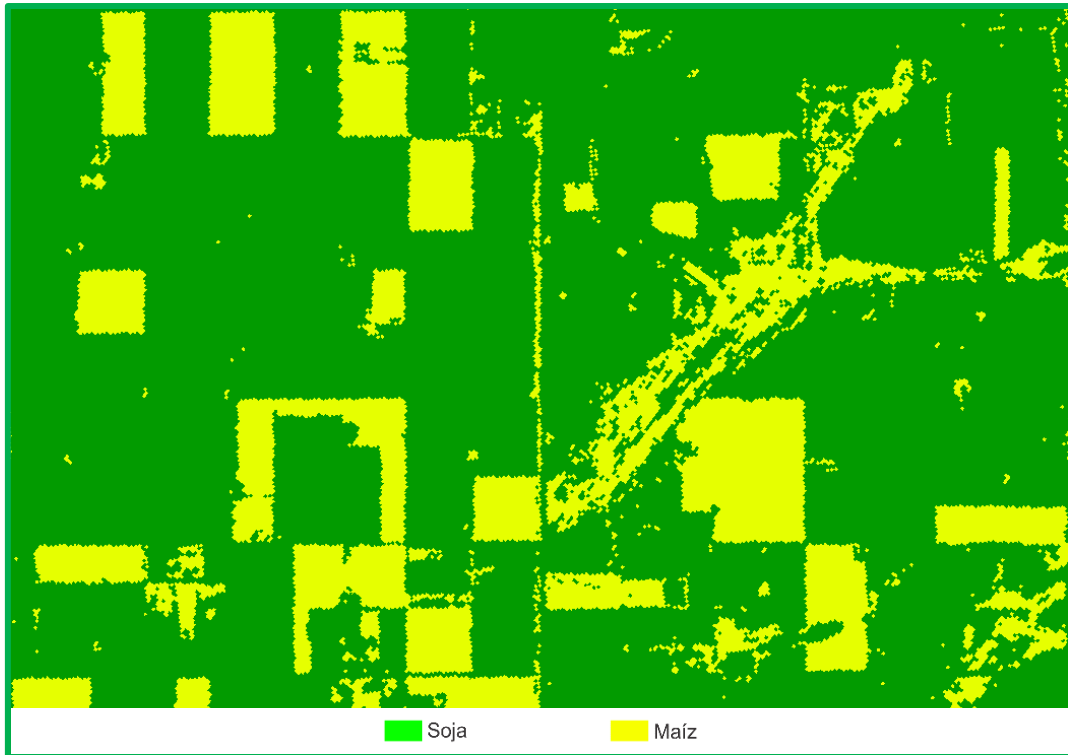


Figura 23. Recorte de escena Landsat 8 del 23/03 sobre el área de estudio clasificada con el modelo svm_7

A fin de examinar los resultados de emplear un tipo de kernel diferente a RBF, se realizó una clasificación haciendo uso del kernel Sigmoideo, y las clases de cobertura de C1 a C10 (modelo svm_5a). Al analizar el mapa resultante se evidencio, de forma significativa, pixeles correspondientes a lotes con cultivo de soja etiquetados erróneamente con la clase maní, del mismo modo pixeles correspondientes a lotes con cultivo de maíz fueron etiquetados con la clase sorgo. Este comportamiento se corresponde con lo obtenido por Rodriguez-Galiano & Chica-Rivas (2012) quienes compararon el desempeño de los kernel lineal, polinomial, RBF y Sigmoideo, exhibiendo este ultimo los resultados menos precisos. En la clasificación de datos derivados del sensoramiento remoto los kernel más comúnmente utilizados son RBF y polinomial (Kavzoglu & Colkesen 2009), por lo cual se procedió a evaluar la aplicación del kernel de tipo polinomial en la clasificación con SVM. La evaluación del mapa generado con el modelo svm_8, el cual clasifica los pixeles solo por soja o maíz, reveló valores de índices de precisión catalogados como excelentes (κ :0,99 y PG:99%) al igual que lo obtenido con el kernel RBF (svm_7). Para próximos trabajos se propone indagar en la conveniencia de usar uno u otro tipo de kernel, según las circunstancias del problema a tratar.

Comparación del desempeño entre algoritmos

Al confrontar las índices de precisión obtenidos con los tres algoritmos, se verifica que MLC logra valores que se catalogan como excelentes en los modelos que consideran únicamente las clases agrícolas. Estos resultados se corresponden con anteriores estudios sobre la misma área geográfica (Willington et al. 2013; Nolasco et al. 2016), y pueden demostrar la estabilidad del algoritmo en este tipo de mapeos. Asimismo, se resalta su bajo costo computacional. En cuanto a los algoritmos derivados del enfoque de aprendizaje automático, SVM logró resultados más precisos que RF, lo cual también fue confirmado en diferentes trabajos de mapeo de cobertura de suelo (Kun. Jia et al. 2014; Nitze & Schulthess 2012; Foody & Mathur 2004; Huang et al. 2002). No obstante en la evaluación del desempeño de los algoritmos realizada por Rodríguez-Galiano & Chica-Rivas (2012), no se encontraron diferencias estadísticamente significativas en las precisiones obtenidas por SVM y RF. Aunque en el mismo trabajo se hace hincapié en el hecho de que el algoritmo de clasificación SVM es más robusto al ruido y la reducción de los datos usados en el entrenamiento. En el mismo aspecto Foody & Mathur (2004) observaron que los clasificadores basados en árboles de decisión son más sensibles al tamaño del conjunto de entrenamiento.

Cuando al modelo de clasificación se ingresa únicamente las clases soja y maíz, los tres algoritmos alcanzan índices de precisión clasificados como excelentes. Esto puede explicarse por el hecho de que los cultivos de soja y maíz ocupan la mayor parte (93%) de la superficie sembrada en el área en estudio, por lo cual es más asequible registrar lotes en los diferentes estadios de crecimiento de estos dos cultivos. Los primeros trabajos de mapeo asienten en este aspecto, Scholz et al. (1979) afirmaron que para la obtención de clasificaciones precisas es más importante, en relación a los algoritmos a utilizar, una buena metodología de entrenamiento en la cual todos los tipos de cobertura en la escena deben estar adecuadamente representados.

Con respecto a los inconvenientes encontrados en la ejecución de los algoritmos de clasificación, se concuerda con Zhong (2012) en que la escasez de muestras de verdad de terreno para el entrenamiento del algoritmo actúa como el factor más limitante en el mapeo de los cultivos usando el enfoque MLC. Respecto a los algoritmos SVM y RF se subraya la necesidad de ajustar de modo artesanal los parámetros asociados a cada clasificador. La bibliografía en el tema brinda aproximaciones, sin embargo no se sabe de antemano cuales son los mejores para un problema dado (Hsu et al. 2003). En este sentido SVM es más complejo, en número y tipo de parámetros a ajustar, respecto RF (Rodríguez-Galiano & Chica-Rivas 2012). Por último en lo que respecta a la demanda computacional se destaca los requerimientos por parte de SVM, en lo referente a la optimización de los valores de penalidad C y del parámetro γ . Este costo aumentaba considerablemente con el número de clases y tamaño del conjunto de entrenamiento. Con respecto a los tiempos de entrenamiento, en el estudio efectuado por Huang et al. (2002) cuando se duplicó el tamaño de los datos de entrenamiento a ingresar a SVM, el tiempo de entrenamiento aumento en una proporción mayor.

Por último teniendo en cuenta estas ventajas y desventajas, y con el fin de hacer uso únicamente de los méritos de cada clasificador, según el desafío de mapeo y los recursos disponibles, Foody & Mathur (2004); Rodríguez-Galiano & Chica-Rivas (2012) plantean como promisorio el uso de conjuntos de clasificadores en fin de alcanzar mejores precisiones.

Síntesis

Actualmente en el área central de la provincia de Córdoba los patrones de rotación se caracterizan por ser de alta intensidad, con la implantación de uno o dos cultivos en la misma campaña agrícola, y escasa presencia de cultivos perennes. Este escenario refleja la necesidad de un enfoque de mapeo efectivo y eficiente -en tiempo y espacio- que permita monitorear la evolución del mismo. En el presente capítulo, se analizó la performance de datos satelitales en el mapeo de tierras dedicadas a cultivos agrícolas, haciendo uso del algoritmo de clasificación de máxima verosimilitud (MLC) y de dos algoritmos derivados del enfoque de aprendizaje automático. Con respecto a estos últimos, se evaluaron los algoritmos Random Forest (RF) y Support Vector Machine (SVM). En los tres casos, se utilizó una escena individual Landsat 8, libre de nubes, adquirida a fines de marzo de 2016 (momento en el que los cultivos se encontraban en etapas reproductivas). Como dato de entrada se utilizaron bandas en la región del visible e infrarrojo cercano. Los modelos de clasificación se validaron utilizando el parámetro de Precisión Global y estadístico Kappa. Los datos para el entrenamiento y validación se obtuvieron de registros a terreno, con fecha de muestreo próxima a la de adquisición de la imagen.

Los resultados que se obtuvieron en el presente capítulo manifiestan que las imágenes de reflectancia de la superficie del suelo, posibilitan el mapeo de la diversidad de coberturas presentes en el área de estudio, con anterioridad a la finalización del ciclo de las mismas. Las mejores precisiones se alcanzaron cuando se utilizaron grupos de entrenamiento y validación, conformados por clases que se limitaban a un estadio específico del ciclo de cada cultivo (precisiones globales e índice Kappa (κ) del 99 por ciento y 0.99 respectivamente). Estos excelentes comportamientos se basan en un riguroso trabajo de campo, en lo que respecta a la recolección de muestras representativas de todas las clases de interés sobre el área de estudio y posteriormente, a gabinete, la determinación de clases de entrenamiento puras. De esta forma los algoritmos de clasificación pudieron lograr una discriminación, incluso entre clases de cultivos que poseían similares patrones fenológicos.

Específicamente cuando se utilizó el algoritmo MLC, se constató la simplicidad y sencillez de ejecución del método, como así también su bajo costo computacional. Los índices de precisión demostraron un muy buen desempeño del algoritmo en el mapeo de cubiertas exclusivamente agrícolas, en correspondencia con anteriores trabajos sobre la misma área geográfica. En lo que respecta al desempeño de los algoritmos derivados del enfoque de aprendizaje automático, se destaca su habilidad para mantener la separabilidad de las clases, aun cuando estas son numerosas, similares y de gran variabilidad interna. Esto demuestra la habilidad de adaptación a problemas no lineales. Comparativamente el algoritmo SVM evidencio mejores precisiones que RF, y ser más robusto a la presencia de ruido y al tamaño del conjunto de entrenamiento.

En contraste las deficiencias de cada enfoque de clasificación se hicieron evidentes. Debido a la característica paramétrica del clasificador de máxima verosimilitud, las altas precisiones alcanzadas en este estudio dependieron considerablemente del tamaño y confiabilidad del conjunto de entrenamiento. El algoritmo MLC incurrió en desaciertos cuando se ingresaba al modelo clases muy heterogéneas. Respecto a los algoritmos SVM y RF sobresale la necesidad de ajustar de modo artesanal los parámetros asociados a cada clasificador. Por último en términos de costos computacionales, la ejecución de SVM por medio de la librería *libsvm* exhibió mayores requerimientos específicamente en la etapa de optimización de sus parámetros (comparando tiempos de procesamiento, al utilizar análogos conjuntos de entrenamientos, software, y hardware).

Es necesario recalcar que la fortaleza y potencialidad de los métodos aquí presentados se sustentan en características inherentes al problema en estudio, como lo son la dimensión de los establecimientos en el área de estudio (media=100ha, que permitió eliminar píxeles de las borduras), la poca cantidad de especies cultivadas, y el contraste de las principales familias botánicas. También se debe nombrar la disponibilidad de datos espectrales clave, convenientes resoluciones espaciales y temporales. Se destaca la importancia de contar con imágenes libres de nubes en fechas en la cual la diferenciación espectral de las diferentes cubiertas se maximiza. Estas consideraciones posibilitan la elaboración de mapas precisos y exactos, con antelación a la finalización de las campañas agrícolas, lo cual es beneficioso para la planificación, estimaciones y generación de presupuestos.

Finalmente se considera relevante recalcar que varios aspectos del presente estudio pueden ser desarrollados en mayor grado. Uno de ellos es analizar la relación entre el método de clasificación y tipo de cobertura del suelo. La divergencia en los resultados obtenidos alienta a futuro plantear estudios que indaguen en este tópico, a fin de explorar estrategias de clasificación que integren más de un algoritmo y grupo de clases. Del mismo modo se considera promisorio la inclusión de la multi-temporalidad en el análisis.

Capítulo 5

Mapeo de cultivos agrícolas en base a datos espectrales y de verdad de terreno no contemporáneos

Trabajando con datos de campo correspondientes al área central de la provincia de Córdoba, los algoritmos de clasificación probados en el capítulo anterior, demostraron ser competentes en el mapeo por tipo de cobertura agrícola. En otros puntos del globo el mapeo preciso de los cultivos de maíz y soja, también ha sido alcanzado con éxito. No obstante en el empleo de estas metodologías se debe tener en cuenta las deficiencias específicas de cada método. Así mismo, es necesario enfatizar que tales esfuerzos de mapeo se basan en datos de referencia de uso del suelo correspondientes al análogo año en estudio. Sin embargo poseer conjuntos de datos de referencia a terreno sobre el tipo-estado de los cultivos, para un lugar y momento específico es una situación excepcional, ya que acarrea significativos esfuerzos y costos de muestreo previos.

Las complejas condiciones ambientales, la diversidad de agro-ecosistemas, la variabilidad en las estaciones de crecimiento de los cultivos y el carácter instantáneo de las imágenes satelitales, las cuales se limitan a proveer capturas transitorias de las condiciones superficiales (Zhong et al. 2014), restringen el uso interanual de esta información. En este sentido, en el presente capítulo, se explora la posibilidad de suprimir el requerimiento de datos de referencia, mediante la depuración y extracción de firmas espectrales representativas a cada cultivo y etapa fenológica. Por lo tanto, las pruebas llevadas a cabo, parten de la condición inicial, de que los conjuntos de datos de entrenamiento y validación proceden de campañas agrícolas distintas. De esta forma se pretende generar un conjunto de datos de referencia para la campaña agrícola 2012-2013, y así posibilitar un adecuado análisis de los datos SAR disponibles (capítulo 6).

Una multiplicidad/variedad de técnicas que incluyen al enfoque de análisis orientado a objetos, la extracción de estadísticos robustos, el análisis de distancias, y la clasificación empleando SVM son exploradas con la finalidad de desarrollar un procedimiento de mapeo independiente de datos de referencia a terreno. La introducción a estas técnicas y la motivación para el desarrollo de este tipo de metodologías de clasificación fueron descritas en los capítulos iniciales del presente trabajo de tesis.

Materiales y métodos

Área de estudio

El área de estudio analizada comprende una ampliación de la superficie mapeada en el capítulo 4, ubicada en el área central de la provincia de Córdoba. Este aumento en la superficie analizada se debió a la presencia de nubosidad en parte de la región objeto de análisis (07 de marzo de 2013). Este hecho limitó el procesamiento de la imagen, en consecuencia el área a analizar se extendió a regiones próximas libres de nubosidad. Estas regiones vecinas, denotaban los mismos atributos (tamaño de lotes, cultivos, suelos) que para el sub área de estudio original. Asimismo se encontraban espacialmente en el análogo path & row de la escena satelital Landsat.

Procesamiento de los datos de entrada

Datos satelitales

Para presente estudio se utilizaron imágenes correspondientes a los satélites Landsat 7 y Landsat 8 (path/row: 229/82) adquiridas en momentos de final de ciclo de los cultivos. La descarga de las mismas se realizó desde el sitio web del Servicio Geológico de los Estados Unidos (<http://earthexplorer.usgs.gov/>). Las fechas de adquisición y correspondiente sensor se especifican en la Tabla 16

Tabla 16. Fechas de adquisición de imágenes

Satélite	Año 2013	Año 2016
Landsat 7 (L7)	07 marzo	15 marzo
Landsat 8 (L8)	16 de abril	23 marzo

El procesamiento de las imágenes, incluyó en una primera instancia el reescalado y calibrado de los DN a valores de reflectancia en el techo de la atmosfera TOA, usando para ello los coeficientes radiométricos provistos en el archivo de metadato "MTL.txt". Se prosiguió para los provenientes del sensor OLI (L8) según lo descrito por Ariza (2013) y en el caso de L7 se efectuó conforme lo especificado en Chander et al. (2009). Por último se realizó un recorte de las imágenes, acotándola al área de estudio, con el fin de reducir el tiempo de ejecución de los cálculos computacionales.

Datos de referencia a terreno

Para la construcción del conjunto de entrenamiento, se utilizó la base de datos de tipos de cobertura de la campaña agrícola 2015-2016 descrita en el capítulo 4. En lo que respecta a la base de datos de validación de los tipos de cobertura presentes en la campaña 2012- 2013, se emplearon datos de un relevamiento de 17 lotes agrícolas. Este último muestreo se efectuó en el periodo de post – cosecha (campaña 2012 - 2013). Del análisis de los residuos de cosecha se determinó el cultivo implantado en la mencionada campaña. Por este motivo, cabe mencionar, que no se disponía de información precisa sobre fechas de siembra y estado sanitario de los cultivos. Sin embargo el objetivo último de la clasificación fue diferenciar tipos de coberturas en las grandes familias botánicas (Gramíneas - Leguminosas). A partir de esta información es posible inferir el volumen de residuos post cosecha y grado de cobertura del suelo.

Análisis, depuración y generación del nuevo conjunto de datos de referencia a campo

Segmentación

En primera instancia las imágenes de la zona de estudio fueron segmentadas en objetos constituidos por varios pixeles. Para ello se utilizó el algoritmo Meanshift implementado en la caja de herramientas de Orfeo, presente en el software QGIS 2.14. El ajuste de los parámetros asociados al algoritmo, fue dirigido a fin de obtener objetos cuyos límites se asemejaban al de las parcelas agrícolas. Para ello múltiples combinaciones de los parámetros *radio espacial*, *número de iteraciones* y *tamaño de objetos* fueron probadas, a fin de conseguir un resultado conveniente. Una descripción detallada del procedimiento de segmentación y parámetros asociados, se proporciona en la página web del software (<https://www.orfeo-toolbox.org/packages/OTBCookBook.pdf>). La combinación finalmente seleccionada fue 5, 200, y 75 para los parámetros *radio espacial*, *n° máximo de iteraciones* y *tamaño mínimo* respectivamente.

Selección de lotes y extracción de estadísticos

A partir de la imagen L8 de 2016, los segmentos generados y sus correspondientes datos de referencia a campo, se realizó una selección de los objetos correspondientes a lotes con cultivos de soja, maíz y maní en sus diversos estadios fenológicos. Esta información se incorporó en un nuevo atributo del archivo vectorial denominado “tipo de cultivo”. Este archivo vectorial con los objetos etiquetados fue utilizado sobre la imagen L7 del 2016, con el fin de calcular los estadísticos mediana, desvío estándar y n° de píxeles en cada banda de la imagen. Posteriormente se verificó el valor del estadístico desvío estándar, con el fin de eliminar objetos conformados por conjuntos de píxeles muy heterogéneos. Por último se recalculó el estadístico mediana para cada tipo de cultivo en su correspondiente etapa fenológica (es decir la mediana de varios objetos). Esta información permitió confeccionar las firmas espectrales de los cultivos representativos.

Seguidamente se prosiguió con el procesamiento de los datos espectrales correspondientes a la campaña 2012 – 2013. La imagen L8 fue sometida a un proceso de segmentación guiándose por el procesamiento realizado a la imagen L8 de 2016. Como resultado se obtuvo un mapa vectorial cuyos objetos se adaptaban a la forma y homogeneidad de los lotes agrícolas. Sin embargo debido a la heterogeneidad innata de los lotes, coexisten segmentos irregulares y de menor tamaño. Por este motivo se realizó un filtrado de los objetos menores a 200 píxeles de tamaño. En lo que respecta a la imagen L7, debido al defecto producido por la falla del instrumento “Scan Line Corrector”, se procedió a eliminar los píxeles con datos faltantes y defectuosos. Sobre la imagen resultante se situó el mapa vectorial y se procedió al cálculo de los estadísticos media y desvío estándar de cada una de las bandas, dentro del perímetro de cada objeto. Estas variables se grabaron como dos nuevos atributos del archivo vectorial.

Generación de nuevo conjunto de verdad de terreno

Los dos conjuntos de referencia creados fueron exportados en formato de tabla al software estadístico Infostat (Di-Rienzo et al. 2016). En el mismo se procedió a realizar un análisis de distancias. Se calcularon las distancias entre los estadísticos de los segmentos de la imagen L7 2013 y las firmas espectrales representativas generadas con los datos de la campaña 2015 – 2016. Para el cálculo se utilizó la métrica distancia euclidiana. Luego se identificaron los segmentos cuya distancia euclidiana en relación a las firmas espectrales no superaba el valor de 0,04, y se procedió al etiquetado con la correspondiente clase. Estos segmentos etiquetados conformaron el nuevo conjunto de verdad a terreno para realizar la clasificación de los datos espectrales de la campaña agrícola 2012 – 2013.

Metodología de clasificación utilizada

Algoritmo de clasificación

Para realizar la clasificación se utilizó el algoritmo Support Vector Machine, el cual conforme a las pruebas realizadas en el capítulo 5, evidencio convenientes resultados para la zona en estudio. La descripción del algoritmo, el software utilizado, y los parámetros asociados al algoritmo se describe en capítulos anteriores. Se fijó un valor de 0,3 para el parámetro *relación entre tamaño de muestras de validación y entrenamiento* (V/T) y **Radial Basis Function** como *tipo de kernel svm* (KT). Adicionalmente se utilizó un archivo con los estadísticos media y desvío estándar de cada banda de la imagen, el cual es requerido por el programa para centrar y reducir los píxeles de entrada.

A los mapas resultantes se les realizó un post procesamiento, aplicando un filtro de mayoría (OTB Team 2016). Se aplicaron 2 tamaños de ventana 3x3 y 5x5.

Validación

Debido a que las clases de entrenamiento y validación no se correspondían en su totalidad, para la evaluación de los mapas resultantes, se optó por una metodología alternativa a la presentada en el capítulo 5. Se procedió al cómputo de una matriz de clasificación, la cual comparaba las coincidencias en número de píxeles, entre las clases de la clasificación y las de referencia a campo. Este último conjunto deriva del relevamiento de los 17 lotes agrícolas de la campaña 2012 - 2013. En analogía con una matriz de confusión (Congalton 1991) se calcularon los estadísticos, ahora renombrados, Pseudo-precisión del productor y usuario, y los estadísticos Precisión Global (PG) y estadístico Kappa (κ).

Un esquema conceptual de la metodología propuesta en el presente capítulo de tesis es presentada en la Figura 24, incluyéndose el uso que se le dará en el presente trabajo de tesis, al mapa generado.

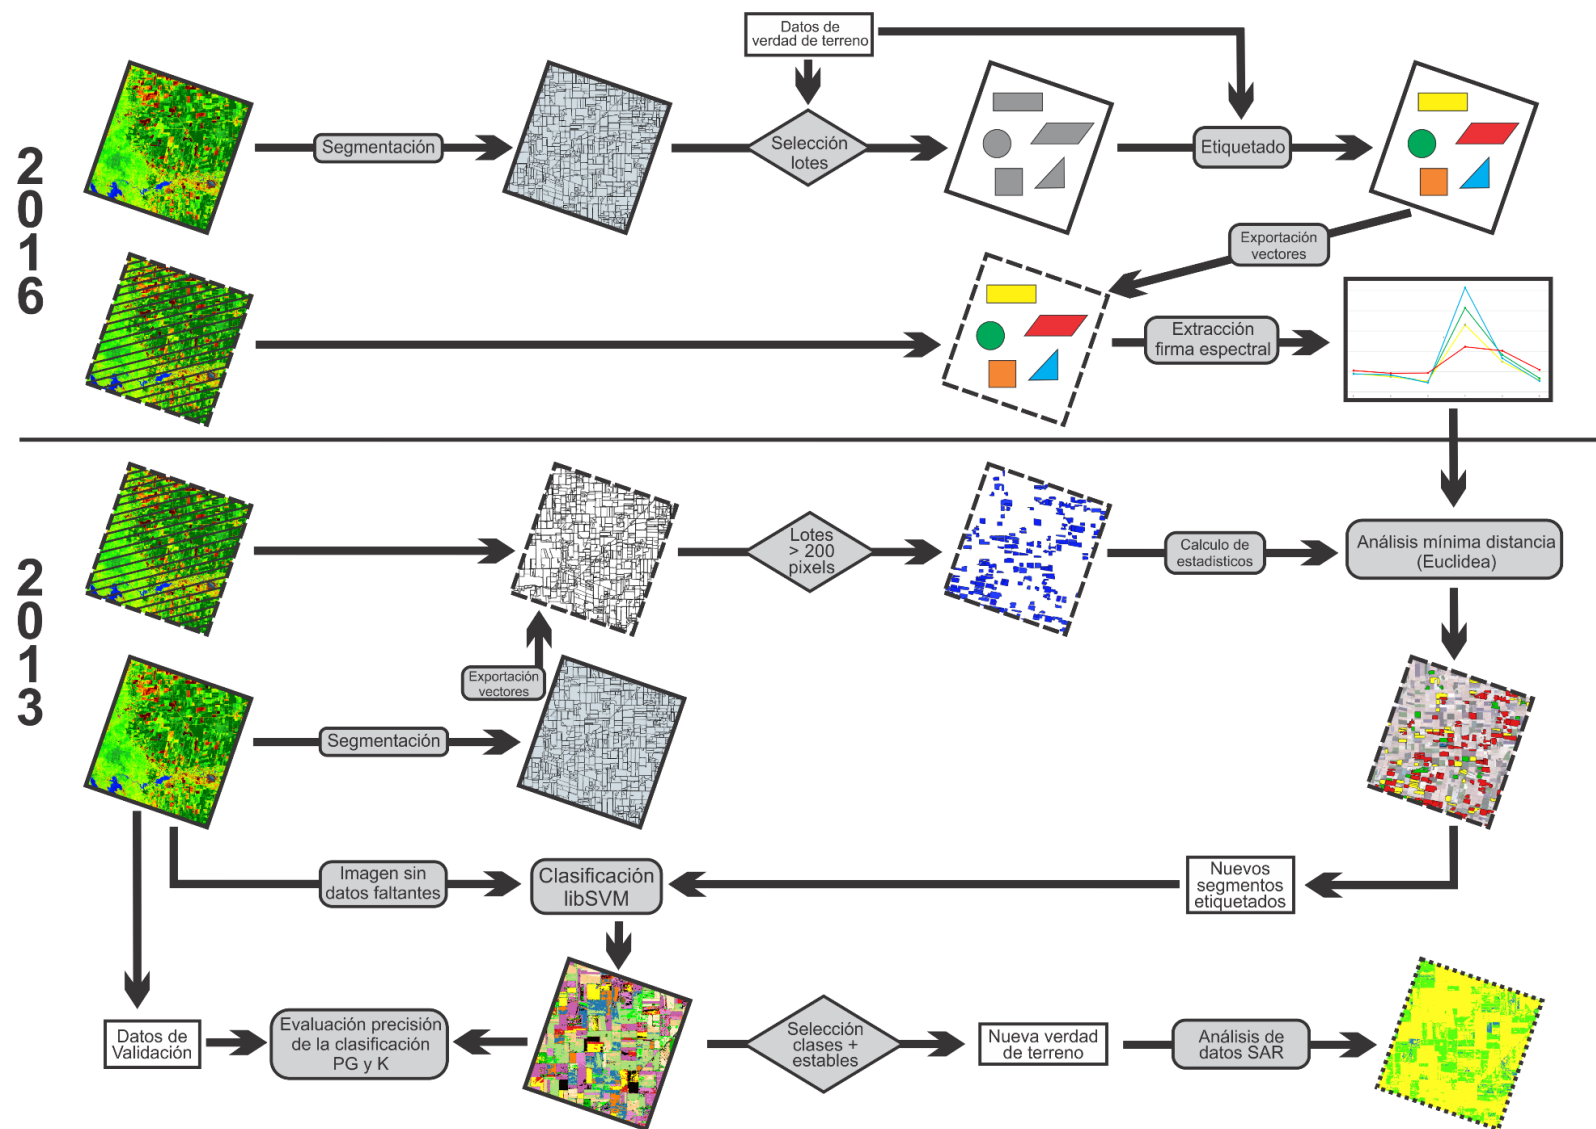


Figura 24. Metodología de procesamiento y clasificación de datos.
 Imágenes L8 con contorno de línea continua, imágenes L7 con contorno de guion, Imagen Radar con contorno punteado.

Resultados y discusión

Segmentación

Como fue mencionado en el apartado de materiales y métodos, se realizaron múltiples pruebas, con el fin de ajustar los parámetros asociados. Tomando como entrada las bandas espectrales de las imágenes L8 del área de estudio (Figura 25), los resultados eran muy disímiles. Desde un único segmento que agrupaba todo el área de estudio, objetos que agrupaban más de un lote (Figura 26), a objetos de reducida superficie que fragmentaban un lote con cultivo homogéneo (Figura 27). En el primer caso el parámetro número de iteraciones restringía la creación de objetos. Seguidamente el parámetro de mayor peso, en la determinación de la dimensión de los objetos, fue *tamaño mínimo*. Finalmente se eligieron valores de compromiso, que generaban objetos acorde a la forma del lote y la homogeneidad dentro del mismo (Figura 28). Es decir se aceptaron divisiones dentro de un lote, especialmente en los de mayores dimensiones (> 200ha). Es de resaltar que en el caso de los segmentos de mayor tamaño, estos son capaces de agrupar las clases más heterogéneas (urbano, “pozo” de infiltración, cubiertas vegetales heterogéneas). Este hecho se podría utilizar con el fin de confeccionar máscaras, para a posteriori excluir estas áreas de los análisis exclusivamente agrícolas.



Figura 25. Recorte de la imagen Landsat 8 color real, sobre área de estudio, con fecha 23 marzo de 2016



Figura 26. Resultado de segmentación sobre el área de estudio. Los objetos sobreestiman el tamaño de los lotes (Encerrados con un círculo amarillo se señala varios lotes incluidos en un mismo segmento).



Figura 27. Resultado de segmentación sobre el área de estudio. Se subestiman el tamaño de determinados lotes (El círculo amarillo señala objetos que fragmentan un lote).



Figura 28. Resultado de segmentación sobre el área de estudio elegida para la extracción de estadísticos representativos.

Firmas espectrales representativas

Efectuado el proceso de segmentación y extraídos los estadísticos distintivos, se computaron y elaboraron gráficamente las firmas espectrales de los cultivos representativos. Para los tipos de cobertura representativos, en la Tabla 17 se presentan los valores de la mediana y desvío estándar de cada banda de la imagen L7 en valores de reflectancia. En la Figura 29 se exhibe un boceto de las firmas espectrales. Es posible observar cierto aglomeramiento en los valores de infrarrojo cercano (banda 4) correspondientes al cultivo de soja en sus estadios fotosintéticamente activos, comportamiento similar ocurre con las relativas al cultivo de maíz en sus estadios fotosintéticamente activos. Los estadios avanzados muestran el aumento de la reflexión y absorción característica en las bandas rojo e infra-rojo respectivamente. El cultivo de maní denota una relación infrarrojo/rojo excepcional. Dicha relación se evidencia en su respectivo valor de NDVI (Tabla 17), el cual es superior al resto de las coberturas, sutilmente mayor al tipo soja extra tardía. En general se constató un aumento en los valores de NDVI y reflectividad de la banda infrarroja en el siguiente orden; cultivos en etapas avanzadas, maíz activo, soja activa, y maní. Sims & Gamon (2002) trabajando con un amplio rango de especies, sugieren que la reflectancia a nivel de superficie de la hoja es un porcentaje mayor de la reflectancia total en el visible que en el infrarrojo. Esto se debe a las vellosidades presentes en la superficie de la hoja, que aumentan la reflectancia en toda la región visible del espectro, pero su efecto en el infrarrojo cercano es pequeño (Slaton et al. 2001). En contraste la dispersión de la luz en el espectro del infrarrojo está positivamente relacionada con las discontinuidades en la estructura interna de las hojas (Gausman 1974). (Slaton et al. 2001) encontraron que la reflectancia entorno a los 800 nm no estaba relacionada con el grosor de la hoja, sino que dependía del porcentaje de espacio aéreo intercelular y la relación entre el área superficial del mesófilo y el área foliar. Blackburn (1999) comprobó que las mediciones sobre pilas de hojas, también muestran incrementos en la reflectancia del infrarrojo cercano hasta el grosor de aproximadamente ocho hojas. Estos argumentos se corresponden con la estructura morfológica

de los cultivos estudiados, más específicamente en lo que respecta a la disposición de las hojas, y explicarían la diferencia de sus reflectancias en la región del infrarrojo cercano. Para los cultivos de soja y maní, sus hojas se disponen de forma pseudo planofila, formando un canopeo “cerrado” a la penetración de luz. En esta situación la luz roja es absorbida mayoritariamente, mientras que las ondas infrarrojas son reflejadas al estar el suelo completamente cubierto por la vegetación (Reddy et al. 2001). En el caso del maíz, sus hojas se disponen principalmente de forma más vertical (erectofila). En esta situación la luz roja es mayoritariamente absorbida por la canopia, y la reflectancia en esta región del espectro proviene mayormente del estrato superior del dosel del cultivo. Mientras tanto, la energía en el espectro del infrarrojo cercano, es afectada principalmente por la dispersión de las hojas, pudiendo alcanzar las capas más profundas (Gitelson et al. 2014). Esto puede explicarse también por un espaciado más amplio entre los surcos, estableciendo una mayor exposición del suelo. De esta forma los lotes con cultivo de maíz exhiben una menor reflectancia en el espectro del infrarrojo cercano, respecto a los de soja y maní (Senay et al. 2000). Comprender esta interacción entre la estructura del canopeo y la energía reflejada en cada intervalo del espectro electromagnético en estudio, permite determinar el tipo de interacción que acontece, y que es inherente a cada cultivo. Este hecho puede posibilitar la confección de reglas de clasificación más robustas y certeras, como así también entender los errores que se producen, como es el caso de la mixtura de clases.

Con respecto a la información que brindan las bandas infrarrojas de onda corta (bandas 5 y 7), existen amplios trabajos que comprueban exitosamente su utilidad en la estimación del contenido de agua foliar (Ullah et al. 2013; Chen et al. 2005; Jackson et al. 2004). Así mismo se ha reportado su conveniencia en la estimación de biomasa de cultivos agrícolas (Zheng et al. 2016). Si bien se han reportado mejoras en la discriminación de cultivos, al introducir a los modelos de clasificación datos de esta región del espectro (Peña-barragán et al. 2011), no se han encontrado trabajos que expliquen específicamente los mecanismos físico-químicos que acontecen. Específicamente entre el canopeo de los cultivos de soja-maíz y la energía registrada por las bandas SWIR. Para el cultivo de maíz, se infiere una mayor absorción en la banda 5 relacionada a la mayor biomasa y por ende mayor contenido hídrico de este cultivo.




Figura 29. Firmas espectrales de clases de cobertura de cultivos (Landsat 7, 15 marzo 2016).

Tabla 17. Valores de los estadísticos mediana y desvío estándar (DE) de cada banda de la imagen L7 (fecha de adquisición 15/03/2016) para los tipos de cobertura en valores de reflectancia. Se acompaña su respectiva magnitud de NDVI.

Banda de L7 y estadísticos	Maní	Maíz extra temprano	Maíz intermedio	Maíz tardío	Maíz extra tardío	Soja temprana	Soja intermedia	Soja tardía	Soja extra tardía
1 mediana	0,09	0,10	0,09	0,09	0,09	0,10	0,09	0,09	0,09
1 DE	0,02	0,04	0,03	0,03	0,03	0,03	0,03	0,03	0,04
2 mediana	0,08	0,08	0,07	0,07	0,07	0,09	0,08	0,08	0,07
2 DE	0,02	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03
3 mediana	0,04	0,08	0,05	0,05	0,04	0,09	0,05	0,04	0,04
3 DE	0,01	0,03	0,02	0,02	0,02	0,03	0,02	0,02	0,02
4 mediana	0,51	0,21	0,29	0,33	0,34	0,25	0,41	0,43	0,45
4 DE	0,10	0,07	0,11	0,12	0,13	0,09	0,16	0,15	0,20
5 mediana	0,17	0,19	0,13	0,15	0,13	0,22	0,18	0,18	0,19
5 DE	0,03	0,07	0,06	0,06	0,05	0,08	0,07	0,06	0,09
7 mediana	0,05	0,10	0,05	0,06	0,05	0,12	0,07	0,07	0,07
7 DE	0,01	0,04	0,03	0,03	0,02	0,04	0,03	0,03	0,03
NDVI	0,84	0,44	0,71	0,73	0,77	0,47	0,78	0,81	0,83







Análisis de distancias

El mapa vectorial generado a partir de la imagen L8 2013 se utilizó sobre la imagen L7 del mismo año, para la extracción de los estadísticos mediana y desvío estándar. De la totalidad de segmentos fueron seleccionados aquellos cuya dimensión superaba los 200 píxeles (aproximadamente 1400 objetos). Con los estadísticos espectrales de estos segmentos (campaña 2012-2013) y los valores de las firmas espectrales de los cultivos representativos de la campaña 2015-2016, se realizó un análisis de distancias. Tomando como umbral un valor en métrica euclídea= 0.04, se identificaron 474 objetos cuyas distancias eran iguales o menores.

Al analizar el conjunto de objetos, se observaron distancias menores al umbral entre un objeto sin etiquetar y más de una firma representativa. Dentro de estas situaciones fue posible identificar dos comportamientos característicos: primero el que incluyó a las firmas representativas de cultivos maíz y soja en fin de ciclo, es decir maíz extra-temprano y soja temprana. Un segundo entre las firmas de un mismo cultivo en etapas fenológicas reproductivas fisiológicamente activas. En el primer caso se explica por el hecho de que los cultivos se encontraban en etapas senescentes, con mínimas áreas de tejido verde (activo). En estas circunstancias la energía electromagnética, es reflejada de forma similar por parte de los tipos maíz extra temprano y soja temprana. Al ser tejido prácticamente muerto sus firmas espectrales se asemejan entre si y a la que en la bibliografía se ejemplifica para el suelo seco (Stoner & Baumgardner 1981), con un aumento en la reflectividad del rojo, y un descenso relativo en el infrarrojo. En el segundo caso para cada especie se observa un agrupamiento de los valores alrededor de la firma correspondiente al estadio fenológico llenado de granos. Es decir en los estadios R3-R4 en el caso del maíz y los R5-R6 para el cultivo de soja. Este comportamiento se relaciona con las tasas de asimilación de materia seca por parte de los cultivos, representadas en el presente análisis por los valores de NDVI. Las máximas tasas de asimilación acontecen en los periodos de plena floración, correspondiente con la etapa de floración completa (R2) en soja (Toledo n.d.), y emergencia de barbas en maíz (R1). A partir de estas etapas empieza un periodo de “autodestrucción” de las partes fotosintéticas de la planta, debido a la demanda de carbohidratos y proteínas para el llenado de los granos (Brun 1978). Es por esta razón que los subsiguientes estadios (etapas más avanzadas del ciclo fenológico) muestran una progresiva declinación en el valor de NDVI. El paso de una etapa a otra no es discreto, sino un continuo, por lo que un objeto puede denotar estadísticos que se aproximan en una misma cuantía a dos estadios fenológicos sucesivos.

En base a estos resultados se redefinieron las clases a utilizar en la clasificación: cultivo senescente, maní, maíz avanzado, soja avanzado, maíz activo y soja activo. Este conjunto de segmentos etiquetados conformaron los nuevos datos de referencia de terreno a utilizar en el entrenamiento del algoritmo de clasificación. En la Tabla 18 se describen las clases, número de segmentos y píxeles que conforman este nuevo conjunto.

Tabla 18. Clases y atributos del nuevo conjunto de entrenamiento

Clase	Número de segmentos	Número de píxeles	Clave de color
Maíz activo	70	25240	 Amarillo
Soja activo	169	69196	 Verde claro
Maní	11	5489	 Azul
Maíz avanzado	5	1840	 Naranja
Soja avanzado	38	12288	 Verde oscuro
Cultivo senescente	5	1724	 Rojo

Clasificación

En la Figura 30 se muestra un fragmento de la imagen L8 con fecha de adquisición 16 de abril de 2013 en color real. La Figura 31 representa la misma fracción con los píxeles clasificados en los respectivos tipos de cobertura. Se denota la presencia de las seis clases en el mapa resultante. Mayormente se manifiesta una mixtura entre las especies leguminosas, y de la clase maíz con cultivo senescente.



Figura 30. Recorte del área a clasificar. Imagen L8 color real del 16 de abril de 2013.




Figura 31. Mapa de cultivos resultantes de la clasificación interanual.

Con el fin de atenuar la mixtura de píxeles en las periferias y/o interior de los lotes, se prosiguió con una regularización del mapa de cultivos. El resultado de esta regularización, para los tamaños de ventana 3x3 y 5x5 puede observarse en las Figuras 32 y 33 respectivamente. Este proceso posibilita un análisis más fácil de los componentes del mapa obtenido. Se aprecia una mayor regularización al utilizar el filtro de mayor lado sobre la imagen procesada.




Figura 32. Mapa de cultivo sometido a una regularización con filtro de mayoría de 3x3.




Figura 33. Mapa de cultivo sometido a una regularización con filtro de mayoría de 5x5.

Evaluación de la precisión de la clasificación

En las Tablas 19, 20 y 21 se muestran las matrices de **clasificación**, para el mapa original y los mapas procesados con el filtro de mayoría. Se hace uso del término matriz de **clasificación**, y no de **confusión**, ya que no se disponía de verdad de terreno para validar los cultivos por su estadio fenológico, aunque en el caso de las especies soja y maíz, las salidas de la clasificación si permitían esta separación. Por lo anterior, las Pseudo-precisiones de productor y usuario se calcularon teniendo en cuenta la coincidencia entre coberturas de la misma especie. Estos aciertos se resaltan en negrita.

Tabla 19. Matriz de clasificación del mapeo realizado a partir de la imagen L8 de 16 de abril.

Píxeles de referencia	Píxeles etiquetados producidos						Total	Pseudo-Prec. prod. (%)
	maíz activo	Soja activo	maní	maíz avanzado	soja avanzado	cultivo senescente		
Maíz	354	9	1	98	68	73	603	74,96
Soja	129	1083	107	170	1024	55	2568	82,05
Maní	21	37	0	0	52	0	110	0,00
Sorgo	5	1	0	8	219	95	328	---
Total	509	1130	108	276	1363	223	3609	
Pseudo-Prec. Usu. (%)	69,55	95,84	0	35,51	75,13	---		

Tabla 20. Matriz de clasificación post regularización con filtro de mayoría 3x3.

Píxeles de referencia	Píxeles etiquetados producidos						Total	Pseudo-Prec. prod. (%)
	maíz activo	Soja activo	maní	maíz avanzado	soja avanzado	cultivo senescente		
Maíz	380	0	0	102	62	57	601	80,20
Soja	52	1110	92	57	1150	15	2476	91,28
Maní	22	31	0	0	53	0	106	0,00
Sorgo	0	0	0	1	213	111	325	---
Total	454	1141	92	160	1478	183	3508	
Pseudo-Prec. Usu. (%)	83,70	97,28	0,00	63,75	77,81	---		

Tabla 21. Matriz de clasificación post regularización con filtro de mayoría 5x5.

Píxeles de referencia	Píxeles etiquetados producidos						Total	Pseudo-Prec. prod. (%)
	maíz activo	Soja activo	maní	maíz avanzado	soja avanzado	cultivo senescente		
Maíz	387	0	0	105	61	47	600	82,00
Soja	32	1146	91	29	1223	5	2526	93,78
Maní	20	26	0	0	56	0	102	0,00
Sorgo	0	0	0	0	214	114	328	---
Total	439	1172	91	134	1554	166	3556	
Pseudo-Prec. Usu. (%)	88,15	97,78	0,00	78,36	78,70	---		

Cuando se examina el desempeño de la clasificación, se observan resultados bastante promisorios en lo que respecta a las clases correspondientes a los cultivos de soja y maíz. Las precisiones de usuario reflejan porcentajes muy buenos en especial para las coberturas soja activo y maíz activo. En la Tabla 19 puede apreciarse una menor confusión entre las clases maíz activo y soja activo, con respecto al par maíz avanzado y soja avanzado.

Estos últimos resultados evidencian la posibilidad de realizar mapas de áreas cultivadas con las especies soja y maíz, utilizando datos de referencia de campañas agrícolas de años diferentes. En particular pueden alcanzarse mayores precisiones, si se mapean dichos cultivos en estadios fenológicos próximos a la etapa de floración.

Esta particularidad puede ser utilizada a futuro a fin generar mapas de cultivos más precisos, realizando el etiquetado de las cubiertas de cultivos, cuando los mismos se encuentran empezando su etapa reproductiva. Al respecto Waldner et al. (2015a) expresan que uno de los principales desafíos para incrementar la superficie de tierras de cultivo mapeadas a escala regional, es la disponibilidad de datos de validación apropiados. Cuanto más detallada sea la información a entrar al modelo, más verídica será la clasificación. En el mismo sentido Xiong et al. (2017) afirman que es indispensable poseer datos abundantes y no sesgados para el entrenamiento y validación del algoritmo.

Con respecto a la cobertura maní, la matriz de clasificación no denota coincidencias con los respectivos píxeles de referencia. Esto puede relacionarse con el hecho de que para la evaluación de este cultivo, se disponía de solo un registro, correspondiente a un lote de 12ha aprox. O bien que la clase de entrenamiento no abarco el estadio fenológico del lote utilizado para la evaluación. Sin embargo se destaca que estos píxeles de referencia fueron clasificados mayoritariamente como cobertura de soja, especie de la misma familia botánica. En la clase maní, el mayor acuerdo se produjo con la clase soja avanzado la cual denota más variabilidad en sus valores de reflectancia, respecto a la clase de soja activo. Esta circunstancia puede reflejar la necesidad de definir más de una clase de entrenamiento para el cultivo maní, tal como se realizó para los cultivos soja y maíz.

En cuanto a la clase sorgo, la misma se agregó a la evaluación como clase de referencia, para analizar el comportamiento del algoritmo clasificador. Se observó que dichos píxeles fueron etiquetados principalmente como soja avanzado. Este comportamiento evidencia la disimilitud con las clases maíz activo y avanzado (misma familia botánica), siendo necesario un análisis más detallado, a fin de poder delimitar las firmas espectrales representativas de cada estadio del cultivo de sorgo. Es necesario recalcar que para superar los problemas de falta de datos a campo, presencia de nubosidad y falla en los instrumentos, para la presente clasificación se trabajó con 4 imágenes satelitales, provenientes de 2 sensores distintos. En concordancia a lo expresado por Zhong et al. (2014) las diferencias en la calidad de las imágenes inter-anales y las discrepancias en las etapas de crecimiento sensadas pueden ser dos de las razones para las bajas precisiones de este tipo de clasificaciones.

De manera opuesta a lo descrito para la clase sorgo, para el cálculo de la precisión del usuario de la clase cultivo senescente, no se disponía de verdad de terreno, por lo que no fue posible determinar esta precisión. Es importante aclarar que esta clase se introdujo al análisis, por el hecho de que se trabajó con una imagen correspondiente a la segunda quincena de abril, en la que los cultivos en etapas finales de sus ciclos, se encuentran fisiológicamente menos activos, con sus firmas espectrales semejantes entre si y a la del suelo desnudo, lo que dificulta su discriminación (Bowker et al. 1985). Dicha clase tiene por objetivo agrupar los píxeles que no

pueden ser asignados a una especie en particular, de forma que el clasificador pueda delimitar ese hiperespacio y de esta forma limitar etiquetados desacertados. Por último se aprecia que el proceso de regularización de la imagen elimino los pixeles mixtos dentro de los lotes, proporcionando coberturas más homogéneas, por consiguiente mayores valores de los estadísticos que validan la clasificación fueron obtenidos. En este sentido sobresale el efecto del filtro para depurar pixeles de las clases maíz y maíz senescente dentro de los lotes correspondientes a la clase de referencia cultivo de soja.

Con respecto al cálculo de los estadísticos Pseudo-PG y Pseudo- κ , estos se determinan tomando los pares de las clases a comparar. Como se mencionó anteriormente los mapas resultantes poseen seis clases, mientras que los datos de cobertura para la validación constaron de cuatro tipos, además de no poseer su homóloga en el caso de la clase sorgo. Este hecho imposibilitó el cómputo directo de los estadísticos. Por este motivo se procedió a unir las clase maíz con maíz senescente, la clase soja con soja senescente, la clase maní quedo sin cambios. Al mismo tiempo fueron apartados del análisis las clases cultivo senescente y sorgo por no poseer su clase homóloga. Los valores de los índices Pseudo- κ y las Pseudo- precisiones globales (en porcentaje) para cada mapa se exponen en la Tabla 22. En primera instancia se puede observar como el proceso de regularización de la clasificación, mejora los índices de precisión. Pasando de un Kappa catalogado como “suficiente” a uno “muy bueno” para la clasificación regularizada con el filtro de mayoría de tamaño de ventana 5x5. Del mismo modo se aprecia una precisión global que se incrementa hasta alcanzar el 90%. Zhong et al. (2014) usando datos satelitales de Landsat 5 y 7, realizaron clasificaciones interanuales a partir de segmentos con el fin de mapear soja, maíz y otros cultivos en el estado de Kansas, Estados Unidos, logrando precisiones promedio del 82.3%, y máximos de 90%, al utilizar variables espectrales como datos de entrada al modelo. Recientemente Zhong et al. (2016) utilizaron imágenes MODIS para mapear automáticamente los cultivos de soja y maíz, tanto de primera como de segunda, con el propósito de generar mapas por coberturas de soja, maíz y otras en el estado de Paraná, Brasil. Esta estrategia les permitió alcanzar una precisión global y Coeficiente Kappa del 87,2% y 0,804 respectivamente. Los resultados evidencian la conveniencia de dividir una clase correspondiente a un mismo cultivo según sus fechas de siembra, de manera de poder considerar el patrón de reflectancia característico para cada etapa del cultivo. En la misma línea de investigación Matton et al. (2015) y Waldner et al. (2015a) trabajaron en el desarrollo de metodologías capaces extrapolar datos de diferentes campañas con la finalidad de producir mapas de áreas cultivadas sin la necesidad de datos de campo y calibración. Probando estas metodologías en diferentes partes del globo, alcanzaron precisiones globales mayores al 80%. En sus trabajos hacen hincapié en la necesidad de depurar la base de datos y contar con resoluciones espaciales finas para poder obtener registros que describan el estado de los lotes de la forma más precisa y detallada posible. Por otra parte en el presente capítulo se hicieron evidentes las falencias del enfoque de trabajo a nivel de pixel, en el cual la mixtura en el interior de los lotes hizo necesaria una posterior corrección. Este hecho promete oportunidades para el trabajo con el enfoque orientado a objetos, sin embargo los últimos autores manifiestan que los mejores resultados obtenidos con una segmentación previa, deben equilibrarse con el costo adicional de este proceso y los potenciales problemas de ajuste del algoritmo para grandes áreas.

Por otro lado (Xiong et al. 2017) manifestaron que un algoritmo de clasificación no puede ser aplicado a lo largo de varias áreas geográficas, con igual certeza. Dirigir análisis independientes para cada ZAH, en el caso de la provincia de Córdoba, puede permitir enfocar el estudio a zonas agroecológicas determinadas, capturar sus características únicas y poder obtener mejores resultados al realizar clasificaciones interanuales. En este sentido los mismos autores sugieren

en una primera instancia limitar el estudio a las áreas tradicionalmente dedicadas a cultivos por medio de máscaras actualizadas de tierras dedicadas a actividades agrícolas.

Tabla 22. Valores de los estadísticos de validación para los mapas de cultivos

Mapa de cultivos	Pseudo Coeficiente Kappa (κ)	Pseudo Precisión Global (%)
Clasificación original	0,51	81,16
Clasificación Filtro 3x3	0,66	88,14
Clasificación Filtro 5x5	0,71	90,08

Por último es necesario indagar en los recientes estudios que abordan la clasificación automática de coberturas de cultivos (Zhong 2012; Zhong et al. 2016; Waldner et al. 2015; Xiong et al. 2017; Matton et al. 2015), haciendo uso de características fenológicas derivadas de índices verdes. Clasificando cubiertas de suelo utilizando imágenes de MODIS y Landsat en Beijing, China, Jia et al. (2014) lograron identificar de forma competente tipos de vegetación al usar características fenológicas. Los autores infieren que la efectividad se relaciona a los diversos tiempos de siembra de la vegetación analizada, lo cual resulta en diferencias relevantes en los patrones fenológicos que exhiben los lotes de los cultivos. Entre las ventajas del uso de series de métricas fenológicas respecto a clasificaciones basadas en variables espectrales de una sola observación, los autores antes citados indican que son menos afectadas por errores de medición y vacíos temporales en etapas concretas de cada cultivo. Respecto a esto último la interpolación entre fechas de los índices de vegetación, permite superar la variación año tras año de los días libres de nubosidad. Se resalta que este tipo de metodologías son robustas y extensibles a otras áreas.

En referencia a las desventajas inherentes a estos métodos, se menciona que el no disponer de imágenes regularmente distribuidas en la estación de crecimiento de los cultivos, pueden sucederse brechas temporales amplias en la serie temporal de los índices de vegetación. Como resultado, el proceso de ajuste de la curva es afectado y las estimaciones de las métricas fenológicas son menos precisas, causando estimaciones sesgadas en el ajuste de las curvas (perfiles temporales planos del índice de vegetación). Por otra parte la variación interanual del progreso de los cultivos y su cosecha, es una fuente importante de confusión para la clasificación basada en variables fenológicas. Estas circunstancias hacen necesario el estudio de metodologías de mapeo automático de cultivos, que utilicen de forma directa los datos espectrales.

Síntesis

Reunir estadísticas de superficies dedicadas a la agricultura de forma rutinaria y repetitiva en tiempo y espacio es un desafío significativo. El mapeo de las superficies dedicadas a los cultivos de soja y maíz, alcanzan hoy en día muy buenos índices de precisión. No obstante tales labores de mapeo demandan grandes esfuerzos en la recolección de datos de referencia. En este sentido, el presente capítulo de tesis exploró la posibilidad de generar mapas de áreas cultivadas con soja y maíz, sin disponer de datos de campo. Estos nuevos datos de referencia son usados en el capítulo 6, para el análisis de los datos SAR. Para ello un algoritmo clasificador fue entrenado con datos de referencia de una campaña agrícola diferente. Se emplearon imágenes satelitales Landsat 7 y 8 de los años 2013 y 2016, el algoritmo de segmentación *Meanshift*, y el algoritmo de clasificación Support Vector Machine.

En la etapa de generación de segmentos la selección de los parámetros mediante prueba y error permitió obtener resultados acorde a la dimensión y forma general de los lotes. Sin embargo este proceder puede ser demandante recursos para grandes áreas. Estos objetos se utilizaron para extraer los estadísticos espectrales de los lotes. Al comparar los valores de dos campañas agrícolas, pudo definirse un nuevo conjunto de datos de referencia para el año 2013, que diferenciaba por cultivo de soja y maíz próximos a la floración y en estadios más avanzados no senescentes. Para posteriores estudios se proyecta realizar esta etapa del estudio por medio de métodos más rigurosos como la técnica de análisis discriminante.

En la etapa de clasificación propiamente dicha, el mapa resultante manifestó una mixtura de píxeles dentro de los lotes de cultivos. La aplicación de un filtro de mayoría (tamaño de ventana 5x5) permitió pasar de un Kappa catalogado como “suficiente” a uno “muy bueno”. Del mismo modo se aprecia una precisión global del 90% (9 puntos mayor a la original). Cuando se examina el desempeño de clasificación se observan resultados bastante promisorios, en especial en las clases correspondientes a los cultivos de soja y maíz. Este hecho avizora oportunidades para el análisis con el enfoque orientado a objetos. En general estos resultados evidenciaron la conveniencia de considerar los estadios fenológicos de cada cultivo, en la determinación de las clases a analizar. En especial los correspondientes a momentos iniciales de la etapa reproductiva, en la cual es posible una mejor diferenciación. Así mismo las características morfológicas de los cultivos de soja y maíz, determinaron una relación contrastante entre la canopia y la radiación en el espectro del Infrarrojo cercano, lo que posiblemente permitió a mejor discriminación

Por último se subraya la simplicidad y efectividad de las técnicas-metodologías utilizadas. Se resalta la capacidad de la métrica euclidiana en el análisis de distancias, la cual logró identificar correspondencias inter-anales. A si también las capacidades de generalización del algoritmo clasificador, que permitieron la interpolación de las características espectrales a una campaña agrícola diferente, sin necesidad de calibración.

A futuro en fin de proseguir en el análisis se sugiere:

- Trabajar en sub áreas homogéneas, que permitan disminuir los esfuerzos de parametrización del algoritmo de segmentación año tras año.
- Indagar en la clasificación haciendo uso del enfoque orientado a objetos.
- Combinar imágenes de múltiples sensores, para incrementar la frecuencia y mejorar la precisión de los mapas
- Incluir variables auxiliares: de suelo, topográficas y meteorológicas a la base de datos original. Con el fin de distinguir y comprender las heterogeneidades del terreno.

Capítulo 6

Una primera aproximación al análisis de coberturas agrícolas post cosecha por medio de imágenes SAR

Como se mencionó en el capítulo introductorio, las actividades agrícolas deben ser adaptadas para evitar la generación de problemas ambientales como el deterioro del suelo, las emisiones de CO₂, la pérdida de biodiversidad y la erosión hídrica, entre otros (Foley et al. 2011). Cuando un suelo se degrada intensamente, la pérdida de su productividad puede ser irreversible o su recuperación tornarse económicamente inviable (Casas 2001). Algunas de las principales causas de las pérdidas por erosión del suelo, son la escorrentía superficial y una inadecuada cobertura de residuos de cultivos, junto con prácticas agrícolas inapropiadas que conducen a procesos de desertificación a meso y macro escalas (Potter et al. 1995; Ravelo et al. 2011). En este aspecto Potter et al. (1997) concluyeron que los residuos en superficie son eficaces para reducir el impacto de la lluvia y dan lugar a un incremento de las tasas de infiltración.

En los últimos años se han adoptado ampliamente nuevas prácticas de manejo agrícola, como lo es la labranza conservacionista y los cultivos de cobertura (Zheng et al. 2014). Los beneficios de la labranza de conservación son sustanciales y se asocian a la acumulación de residuos de cultivos sobre la superficie del suelo (Alvarez et al. 2014). Desde el aspecto ambiental, los residuos de cultivos tienen influencias positivas en la infiltración del agua, la evaporación, la temperatura y la estructura del suelo (Bocco et al. 2014). La importancia de la cobertura en los suelos agrícolas, también está dada por su asociación con propiedades físicas, químicas y biológicas, que mejoran su potencial de producción (Blough et al. 1990; Morón 2004). Así mismo la degradación de residuos de cultivos es tan relevante como la fotosíntesis; es decir, promueve el secuestro de carbono en el suelo (Daughtry 2001; Morón 2004; Pacheco & McNairn 2010). Estos beneficios se consiguen mientras la fertilización artificial y el consumo de energía se reducen, manteniendo así un ambiente sano para el crecimiento de las plantas (Gelder et al. 2009).

En este contexto, como se ha presentado en capítulos anteriores, la teledetección ofrece la oportunidad de obtener sistemáticamente información que describa las variables relacionadas con los cultivos agrícolas y los suelos de forma continua, eficiente y a bajo costo para grandes áreas (Gelder et al. 2009; Zheng et al. 2012; De Paul 2012). Más específicamente los sensores Radar de Apertura Sintética (SAR), ostentan la capacidad de sortear las condiciones de nubosidad, permitiendo complementar los datos provenientes de sensores ópticos (Chuvieco 2010).

En lo que respecta al estudio de la biomasa muerta, sobre áreas agrícolas, por medio de imágenes SAR, la literatura es reciente y limitada. No obstante, ha habido avances significativos en la comprensión de la interacción entre los desechos de las plantas y los parámetros de la señal del radar. McNairn et al. (1998) trabajando con datos del sensor de Radarsat (banda C, 56 mm) correlacionaron el promedio de retrodispersión a campo con el porcentaje de cobertura por residuos. La regresión lineal obtenida fue estadísticamente significativa ($p < 0,05$) con un coeficiente de correlación moderado ($R = 0,53$), lo que indica un aumento de la retrodispersión

de la señal a mayores porcentajes de cobertura. En el mismo estudio se determinó que los cultivos asociados a tipos de rastrojos gruesos como el maíz tienen un coeficiente de retrodispersión más alto que los asociados a rastrojos finos, como en las legumbres, debido a la pequeña cantidad y a la textura superficial lisa del suelo cuando no es labrado. McNairn et al. (1998); Oh (2008); y Smith & Major (1996), coincidieron en que el contenido de agua presente en el rastrojo es muy importante para determinar la magnitud de su participación en la retrodispersión total.

Poder monitorear los atributos del suelo de forma extensiva no solo es de valor significativo para evaluar los riesgos asociados con la degradación del suelo (Duiker 2011). Esta información de la superficie terrestre es también crítica para la aplicación operativa de los modelos existentes de estimación de la humedad del suelo basados en datos SAR multipolarimétricos (Kornelsen & Coulibaly 2013), pudiendo usarse para estimar los errores producidos por parte de los residuos y/o la rugosidad del terreno (McNairn et al. 2012).

En el presente capítulo se exploró y analizó la aplicabilidad de los datos de radar de apertura sintética en el análisis de coberturas post-cosecha, para la región centro de la provincia de Córdoba. Como se explicitó (capítulo 1), para el año en el que fueron adquiridas las imágenes SAR utilizadas en el presente estudio, se disponía de un conjunto de referencia a campo limitado. Es por ello que se recurrió a los procesamientos y análisis efectuados en los capítulos 4 y 5 con el fin de generar una base de datos de referencia, que permitiera efectuar un estudio más contundente sobre la aplicabilidad de datos SAR en el mapeo de suelos por tipo de residuo agrícola. En una primera instancia se realizó el pre-procesamiento de los datos SAR, el cual incluyó: calibración, multilooking y geocodificación. Seguidamente se evaluaron filtros específicos para la reducción del ruido inherente a las imágenes de radar. Posteriormente a partir de sitios representativos de los tipos de coberturas presentes, se realizó un análisis de la interacción señal – residuos agrícolas, y su variación en el tiempo, haciendo hincapié en el potencial de discriminación por tipo de residuo. Por último, en base a los datos de tipo de cobertura agrícola generados por medio de la metodología propuesta en el capítulo 5, se pudo indagar en la capacidad operativa de los sistemas SAR para generar mapas de cobertura por tipo de residuo agrícola.

Materiales y métodos

Datos de referencia

Los datos de referencia a campo para el análisis de la interacción señal – residuo agrícola, se corresponden con 17 lotes de uso agrícola muestreados a partir de septiembre de 2013 (capítulo 5). A partir del análisis de los residuos de cosecha se determinó el cultivo estival implantado en la campaña 2012- 2013. Dichos cultivos abarcaron: Soja, Maíz, Sorgo y Maní.

Los datos de referencia a campo para el proceso de entrenamiento y validación del mapeo operativo por tipo de residuo agrícola, provinieron del mapa de coberturas generado en el capítulo 5. De este mapa se utilizaron únicamente las clases correspondientes a maíz activo y soja activo, ya que presentaban los mejores valores de los estadísticos que validan los mismos.

Descripción de los sistemas de radar de apertura sintética

Los sistemas SAR pueden adquirir imágenes independientemente de si es de día o de noche y en todas las condiciones meteorológicas. Trabajan dentro de las frecuencias de longitud de onda de 0,1 cm y 1 m. El píxel en una imagen de radar representa el coeficiente de retrodispersión del área en tierra (Chuvieco 2010). La radiación emitida por el radar está polarizada, esto significa que el vector de campo eléctrico tiene una dirección determinada que puede ser vertical,

horizontal (con respecto al plano de tierra) o tener ambos componentes (Figura 34). La radiación al ser reflejada, generalmente experimenta una rotación del vector del campo eléctrico. A continuación, se debe especificar, si el componente horizontal, el vertical o ambos son capturados por el sensor. Por lo que hay 4 posibilidades: HH, HV, VV y VH, donde la primera letra se refiere a la señal emitida y la segunda a recibida (Buemi 2012).




Figura 34. Representación del campo eléctrico y polarización. Fuente: Canada Center for Remote Sensing (2014).

La onda electromagnética se emite en pulsos, y el retorno de las mismas se detecta y almacena para su posterior procesamiento. A partir de los pulsos crudos, un algoritmo llamado procesador SAR produce la imagen (Salvia 2010). Posteriormente los datos de las imágenes SAR deben calibrarse para relacionar los valores digitales de cada píxel con los valores correspondientes al coeficiente de retrodispersión sigma naught σ^0 (Frulla et al. 1998). Este coeficiente representa la reflectividad media de una muestra de material horizontal, normalizada al área en el plano de tierra. Es una fracción que describe la cantidad de potencia retrodispersada comparada con la potencia media del campo incidente. La teoría electromagnética explica que la intensidad de una onda electromagnética es proporcional al flujo medio de energía por unidad de tiempo (potencia), es decir, el valor cuadrático medio del campo eléctrico. Entonces la potencia es proporcional al cuadrado de la amplitud de la onda. Finalmente, los datos en decibelios se obtienen a partir de la relación logarítmica (diez veces el logaritmo del coeficiente de retrodispersión). La Tabla 23 exhibe las correspondencias entre unidades.

Tabla 23. Correspondencias entre magnitudes físicas/radiométricas

Potencia σ^0	Amplitud σ^0_A	Decibelios σ^0_{dB}
σ^0	$\sqrt{\sigma^0}$	$10 \log \sigma^0$

Propiedades del material superficial que afectan la respuesta de la señal

El grado de dispersión de la señal es determinado por la interacción entre las ondas electromagnéticas y la superficie terrestre. En esta interacción dos aspectos resultan fundamentales: sus características geométricas y sus propiedades dieléctricas. A su vez, el patrón de dispersión de las superficies depende principalmente de la rugosidad superficial, mientras que la potencia con la que la señal vuelve al sensor está modulada por las propiedades dieléctricas, es decir, por el contenido de humedad del suelo (Pampaloni et al. 2004). Si una superficie se considera áspera o no, depende de la longitud de onda de la radiación utilizada y del ángulo que forma la onda con la superficie (ángulo de visión). A longitudes de onda largas

muchas superficies aparecen lisas, mientras que las mismas superficies pueden ser rugosas a longitudes de onda más cortas (Richards 2013).

La señal medida por el sensor del radar después de haber interactuado con la superficie de la tierra es la suma de las siguientes aportaciones: a) retrodispersión difusa superficial, b) retrodispersión de objetos debajo del suelo (en materiales muy secos), c) retrodispersión doble rebote (resultado de objetos que forman ángulos rectos con respecto al suelo), y c) dispersión en volumen. En la Figura 35 se representan gráficamente estos mecanismos de dispersión para longitudes de onda de menor tamaño, como la banda X utilizada en la presente tesis.




Figura 35. Mecanismos de dispersión para ondas de longitud corta: a) difusa superficial, b) en profundidad, c) doble rebote, y d) volumétrica (extraído de Richards (2013)).

Interacción con la señal polarizada

Como se mencionó, la señal transmitida puede ser polarizada en el plano vertical y horizontal. El pulso luego de interactuar con la superficie terrestre, vuelve al sensor con menos energía y generalmente en la misma polarización con la que fue enviada. Sin embargo, una parte de la energía es despolarizada por la superficie. Existen teorías que atribuyen esta modificación a múltiples reflexiones causadas por la superficie. Estas teorías se ven reforzadas por el hecho de que los efectos de despolarización de la vegetación y el suelo desnudo son muy marcados. Por estas circunstancias existen sistemas que poseen un segundo modo de adquisición, que recibe el impulso eléctrico transmitido girado 90° . A este tipo de modo se lo denomina polarización cruzada HV o VH (Edrosa 2011).

Trabajando en banda C con polarizaciones VV y HH sobre áreas con residuos agrícolas, McNairn et al. (2002) observaron que las respuestas para ambos modos fueron similares para superficies lisas con ángulos de incidencia agudos con respecto a la normal. Sin embargo, a ángulos más grandes estas respuestas divergen, la retrodispersión en modo de polarización VV es mayor que la retrodispersión en la polarización HH. Por otra parte, las superficies rugosas producen respuestas de retrodispersión similares en HH y VV y en cualquier ángulo de incidencia. Para la mayoría de los suelos que no habían sido cultivados y contenían una cantidad considerable de rastrojo, la retrodispersión en HH fue ligeramente mayor que la retrodispersión VV. La firma de polarización para sitios no cultivados con residuos de especies leguminosas era diferente de otras superficies no cultivadas. Las legumbres dejan menos residuos después de la cosecha y este residuo también tiende a ser muy fino. Estas observaciones sugieren que muy pocos residuos tienen un ligero efecto sobre la respuesta del radar, y estos objetivos aparecen como superficies lisas en la banda C. Sin embargo, los residuos pueden contener suficiente humedad para dejar de ser transparentes a las microondas incidentes. Conocer esta interacción es importante, ya que puede impedir el mapeo de otras variables como lo es la humedad del suelo (McNairn et al. 2001).

Imágenes satelitales

Para la realización del presente trabajo se dispuso de un conjunto de imágenes provenientes de la misión satelital COSMO-SkyMed (Covello et al. 2010). Este es un sensor de tecnología de Radar de Apertura Sintética, perteneciente a la Agencia Espacial Italiana. El mismo trabaja en banda-X (2,5cm). Las fechas de adquisición de imágenes y de muestreo a campo, se detallan en la Tabla 24. Todas las imágenes fueron adquiridas con un ángulo de incidencia de referencia de 40°.

Tabla 24. Fechas de viaje de muestreo a campo y adquisición de imágenes SAR sobre el área de estudio

Fecha de muestreo a campo	Imágenes SAR COSMO-SkyMed		
	Fecha de adquisición	Hora local	Pasada
4/09/2013	31/08/2013	12:59:00	Ascendente
18/09/2013			
09/10/2013	1/10/2013	13:05:00	Ascendente
25/10/2013	26/10/2013	13:47:00	Ascendente
6/11/2013	6/11/2013	00:24:00	Descendente
20/11/2013	23/11/2013	00:24:00	Descendente
03/12/2013	01/12/2013	13:46:00	Ascendente
17/12/2013	17/12/2013	13:46:00	Ascendente

Pre-procesamiento de imágenes SAR

Calibración

Los procedimientos de calibración dependen del sistema procesador del satélite en consideración. A nivel de usuario la calibración se realiza para ajustar cualquier cambio temporal en la ganancia de la antena, en la condición de saturación de la señal y para convertir los valores de amplitud de cada píxel (expresados en contadores digitales) a valores de coeficiente de backscattering o brillo (Laur et al. 2004). Este procedimiento es necesario para estudios multitemporales (como el de la presente tesis) y/o multi-ángulos (Frulla et al. 1998).

Multilooking

Todas las imágenes de radar se ven afectadas en mayor o menor grado por algún ruido. Este aparece como una textura granulada en toda la imagen, la cual se denomina como efecto de "sal y pimienta". Este "ruido" se debe a la suma de ondas electromagnéticas con diferentes fases que causan constantes interferencias constructivas y destructivas, en la señal recibida por el detector en cada píxel (Oliver & Quegan 2004). En general, es un "ruido" no deseado que degrada la calidad final de la imagen y dificulta su interpretación.

Las imágenes producidas por el sistema SAR pueden ser *single look* de datos complejos (*Single Look Complex, SLC*) o en uno o más looks de datos reales. En el caso de imágenes de *single look*, la relación señal/ruido (SNR) es baja, lo que a menudo hace difícil un análisis visual y automático.

Para mejorar la SNR, se utilizan varias técnicas, entre las cuales la más importante es el procesamiento de multilooking. Este proceso se refiere a la división del haz de radar en varios haces estrechos angularmente. Cada sub-haz proporciona una mirada independiente de la escena iluminada. El promedio pixel por pixel de cada mirada genera una imagen multi-looking que tiene menos "ruido" speckle, mejorando la resolución radiométrica a expensas de la resolución espacial (Salvia 2010). El nivel de reducción del ruido está directamente relacionado con el número de looks. Este proceso de generación de múltiples vistas produce imágenes con píxeles aproximadamente cuadrados en tres direcciones: en dirección azimutal, en dirección en rango y ángulo de incidencia (Henderson & Lewis 1998). Dependiendo del propósito del estudio es necesario determinar el número de looks a usar.

Para la cuantificación del número de looks, se debe calcular la media y la desviación estándar de los tipos de cobertura representativos en el área de estudio. Estos objetos deben ser homogéneos. El número equivalente de looks (ENL) se define como la inversa de la varianza de la intensidad de la señal normalizada (Ecuación 3).

$$ENL = 1/qr^2 , \quad qr = \sigma/\mu \quad (3)$$

Donde μ y σ representan la media y la desviación estándar de la intensidad de la señal retrodispersada de un objetivo homogéneo, y qr es la desviación estándar normalizada (Laur et al. 2004).

Filtros reductores de speckle

En los últimos años se han diseñado muchos filtros para reducir el "ruido" speckle. La reducción del moteado se basa en mover una ventana (de dimensión 3x3, 5x5 o mayor) sobre cada píxel de la imagen aplicando una operación matemática que utiliza los valores de píxeles incluidos en la misma. El valor del píxel central se sustituye por el nuevo valor, resultante de la operación matemática. La ventana se mueve a través de filas y columnas de los datos, un píxel a la vez, hasta que se procesa toda la escena. Las posibles operaciones a realizar pueden ser el cálculo de la media, mediana y entre otras. Estos filtros se basan en modelos acordes a las propiedades estadísticas del coeficiente de retrodispersión y del "ruido" speckle. Además, debemos tener en cuenta los parámetros de entrada de los filtros, tales como el tamaño de la ventana, la desviación estándar del moteado y el factor de amortiguación, estos deben ajustarse al objetivo del estudio (Frulla et al. 1998). Por ejemplo, en el caso de regiones heterogéneas con grandes variaciones de tono, es preferible tratar con ventana pequeña. Con respecto a la variación del factor de amortiguación, los grandes valores, preservar mejor los bordes, pero reducen el efecto de suavizado. Por el contrario, valores más pequeños aumentan el efecto suavizante, pero no mantienen los bordes correctamente (Schreier 1993). Una descripción y análisis de los filtros utilizados en las imágenes de radar se puede encontrar en (Mansourpour et al. 2006; Gagnon & Joan 1997; Lee et al. 1994).

Correcciones Geométricas

Las correcciones geométricas se realizan para subsanar las deformaciones que se producen en el proceso de generación de la imagen. Ya sea utilizando un modelo digital de elevación de terreno, para obtener una orto-imagen, o una corrección polinómica asumiendo una superficie plana, dichas correcciones involucran la utilización de técnicas de re-muestreo. Estas incluyen la interpolación radiométrica entre píxeles vecinos. La ecuación de radar generalizada para objetivos extendidos calcula la potencia recibida mediante la suma pesada (en el límite, una

integral) incluyendo valores σ^0 en incrementos de área relevantes. Si se amplía este concepto, la magnitud más adecuada para la interpolación radiométrica en el procedimiento de re-muestreo es σ^0 en potencia. Si el método de interpolación utilizado es el vecino más cercano, el resultado es el mismo independientemente del tipo de representación utilizado para σ^0 . En cuanto a los métodos de re-muestreo, se debe considerar lo siguiente: 1) el método del vecino más cercano mantiene las estadísticas globales, pero cambia la textura local, 2) la interpolación bilineal degrada la resolución, y 3) la convolución cúbica tiende a conservar los valores y texturas locales. Por lo tanto, el último método es recomendado (Frulla et al. 1998).

En este estudio los datos fueron calibrados y geocodificados utilizando el software ENVI 4.8. Para ello se utilizó un modelo digital de elevación del terreno de 90 metros de resolución, derivado de la misión SRTM. Las imágenes SAR fueron corregidas geográficamente a un tamaño de píxel de 15 metros. En la etapa de multilooking, y evaluación de filtros para la reducción del speckle, las imágenes se utilizaron en valores de intensidad. Para la clasificación por tipo de cobertura, los datos de las imágenes fueron procesados en la magnitud decibeles.

Procesamiento de los datos

Evaluación del filtro reductor de speckle

Con el fin de reducir el moteado en las imágenes a analizar, se comparó el desempeño de nueve filtros específicos para imágenes radar: Media, Mediana, Paso bajo, Lee, Lee mejorado, Frost, Frost mejorado, Gamma y Sigma local. Cada uno con 5 tamaños de ventana (3, 5, 7, 9, 11). Se utilizaron criterios cualitativos tales como la comparación visual de imágenes filtradas con respecto a la original. La preservación de los bordes se consideró de menos relevancia, debido a que se buscó una estadística representativa del interior de las parcelas, y se descartaron los píxeles de los márgenes. Por otro lado, se utilizaron criterios cuantitativos basados en las estadísticas de la imagen filtrada y original, como la preservación de los valores originales, la reducción de la desviación estándar y el valor medio de la diferencia absoluta entre la imagen original y la filtrada. El análisis se realizó en sitios representativos de los tipos de cobertura por residuos agrícolas.

Análisis espacial y temporal de la interacción entre la señal y la superficie del suelo

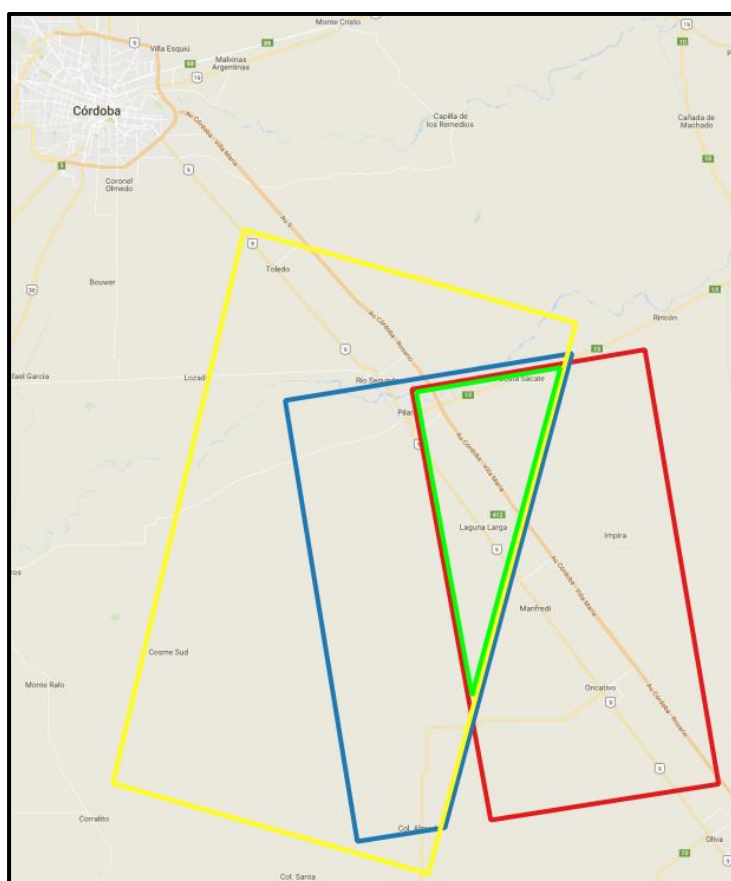
Sobre las imágenes SAR pre-procesadas y filtradas, de las distintas fechas y en ambas polarizaciones, se posicionaron los polígonos correspondientes a los lotes agrícolas de la campaña 2012-2013. De este modo se extrajo el valor de coeficiente de retrodispersión de los píxeles incluidos en los objetos, para su procesamiento en el software estadístico R. Preliminarmente se verificaron los supuestos de normalidad e independencia de los datos.

A partir de los conjuntos de valores de retrodispersión de cada lote, correspondientes a la imagen con fecha de adquisición más cercana a la cosecha y para ambas polarizaciones, se construyeron diagramas de caja. Para comparar los valores de las clases de cobertura, e identificar diferencias estadísticas entre sus medias, se realizó un análisis de la varianza, con test a posteriori de Tukey. En el caso de los lotes con cultivo antecesor correspondiente a maíz, y aquellos que solo exhibían restos de residuos de cultivo de soja, se realizó un estudio multitemporal. En este caso se construyeron diagramas de caja a partir de lotes representativos de estas coberturas, para cada fecha de adquisición y banda de la imagen.

Clasificación supervisada de datos SAR.

Para la clasificación de los datos de radar, las imágenes correspondientes a las distintas fechas y polarizaciones fueron apiladas en un solo archivo. No se realizaron clasificaciones en base a una única imagen SAR, ya que en el modo de adquisición descripto, no se obtienen resultados

satisfactorios (Violini 2016). Las imágenes variaban en la dirección de adquisición (ascendente-descendente), y/o se encontraban desplazadas con respecto al centro del área de estudio. Debido a esto no se correspondían espacialmente en su totalidad. Por lo cual se resolvió realizar clasificaciones de acuerdo a las áreas de conjunción entre imágenes. Cada clasificación abarcó el área de coincidencia entre imágenes de 2, 3, y 4 fechas⁸. Así mismo se realizaron pruebas con una y ambas bandas de polarización. El esquema espacial de la clasificación quedó establecido como se explicita en la Figura 36.



Fechas de las imágenes utilizadas en cada área de clasificación

Área 1
31 de agosto
01 de octubre

Área 2
06 de noviembre
26 de noviembre

Área 3
01 de octubre
06 de noviembre
26 de noviembre

Área 4
31 de agosto
01 de octubre
06 de noviembre
26 de noviembre

Figura 36. Áreas de clasificación con las correspondientes fechas de adquisición de las imágenes intervinientes.

El proceso se realizó en base al enfoque de clasificación pixel por pixel, sin tener en cuenta clases nulas, lo cual forzó a que todos los píxeles sean asignados a una de las categorías definidas en el set de entrenamiento. El algoritmo de clasificación supervisada utilizado fue el de máxima verosimilitud. Para cada área de clasificación el algoritmo fue corrido sobre tres conjuntos de datos: los correspondientes a la polarización HH, a la polarización VV, y a las dos polarizaciones (HH-VV).

Las clases a ingresar en el modelo de clasificación fueron tres: rastrojo de soja, rastrojo de maíz, y verdeo de invierno. Para la generación de los conjuntos de entrenamiento y validación correspondientes a las clases rastrojo de soja y rastrojo de maíz, se utilizaron los datos generados por medio del análisis realizado en el capítulo 5. En el caso de la clase verdeo de invierno, se utilizó un mapa de valores de NDVI del periodo en estudio.

⁸ La imagen con fecha de adquisición 26 de noviembre fue apartada del análisis, por irregularidades en los valores de retrodispersión.

Para este estudio, los datos de referencia de cada categoría se utilizaron en un 50% para entrenar y el 50% restante para validar la precisión clasificación. Los mapas de clasificación a menudo poseen píxeles mal clasificados dentro de polígonos de clases de referencia homogéneas, especialmente en los mapas derivados de datos radar. Para reducir el ruido en estos productos y mejorar las precisiones de la clasificación, la aplicación de un filtro de postclasificación es común (McNairn et al. 2014). Del mismo modo que en el capítulo 5, se procedió con una regularización aplicando un filtro de mayoría (ventana 5x5) sobre las clasificaciones que integraban ambas polarizaciones.

La evaluación de la precisión de la clasificación se realizó por medio de la construcción de las matrices de confusión, y los estadísticos asociados descriptos en el capítulo 4 de la presente tesis.

Resultados y discusión

Evaluación de filtros para la reducción del speckle

Las Figuras 37 y 38 muestran la diferencia porcentual entre el valor medio de los píxeles de las imágenes filtradas (nueve filtros) y la imagen original para los lotes con rastrojo de maíz y soja respectivamente. Las Figuras 39 y 40 exponen la desviación estándar de los píxeles correspondientes a los lotes con rastrojo de maíz y soja respectivamente, para cada tipo de filtro aplicado. Las figuras 41 y 42 muestran el valor medio de la diferencia absoluta, entre los píxeles de la imagen original y la resultante de aplicar los filtros, para los lotes con rastrojo de maíz y soja respectivamente. Los filtros probados fueron (de izquierda a derecha): Media, Mediana, Paso bajo, Lee, Lee mejorado, Frost, Frost Mejorado, Gamma y Local Sigma.




Figura 37. Diferencia porcentual entre el valor medio de los píxeles de la imagen original y filtradas (rastrojo de maíz).




Figura 38. Diferencia porcentual entre el valor medio de los píxeles de la imagen original y filtradas (rastrojo de soja).




Figura 39. Desviación estándar de la imagen original, y filtradas (rastrero de maíz).




Figura 40. Desviación estándar de la imagen original, y filtradas (rastrero de soja).



Figura 41. Diferencia absoluta entre las medias de la imagen filtrada y original (rastrero maíz).




Figura 42. Diferencia absoluta entre las medias de la imagen filtrada y original (rastraje soja).

Las Figuras 37 y 38 sugieren que el filtro Lee es el que mejor preserva el valor promedio respecto a la imagen original con los cinco tamaños de ventana, presentando diferencias menores de 0,8% y 1,8% para maíz y soja respectivamente con respecto al valor medio de la imagen original. El resto de los filtros tienen diferencias que van desde 0.2% a 5.8%, aumentando con el tamaño de la ventana. La desviación estándar en las imágenes filtradas (Figuras 39 y 40) disminuye con el aumento de la ventana de filtrado, lo que indica una disminución en el contenido de la información. La imagen filtrada usando el algoritmo Lee presenta valores más cercanos a la original, lo cual indica una mayor conservación del contenido de la información. Las Figuras 41 y 42 revelan que este mismo filtro produce las menores diferencias en términos de las medias de las imágenes filtradas y sin filtrar, por tanto, una menor pérdida de información. Conforme a estos resultados, Lee puede ser considerado el filtro más apropiado para el problema en estudio. Cabe aclarar que esta conclusión no se puede extrapolar a otras regiones (Lee et al. 1994). En la Figura 43 se adjuntan los recortes de las imágenes procesadas con los distintos filtros.

En trabajos de aplicación de datos SAR para el estudio de la humedad del suelo sobre tierras de uso agrícola, la utilización del filtro Lee brindó convenientes resultados. Van Oevelen (1998), logró con el filtro Lee, una mejor reducción de la varianza espacial de los datos de humedad estimados respecto al filtro de media. Leconte et al. (2004) también con el filtro Lee informaron buenos resultados, destacando como importante que preserva el valor medio del coeficiente de retrodispersión en áreas homogéneas (Lopes et al. 1990). Estudiando la relación entre la humedad del suelo y datos SAR en banda C, Glenn & Carr (2003) realizaron un análisis en la gran cuenca del lago Winnemucca, Nevada, en un área topográficamente plana, sin vegetación y uniforme, con mínima rugosidad superficial. Para la eliminación del ruido del moteado y la variación local en los valores de pixel propios de las imágenes radar, utilizaron los filtros adaptativos mediana y Lee. Estos filtros proporcionaron una imagen más suave preservando la resolución espacial, estadísticamente redujeron la variabilidad de los datos dando como resultado valores más "adaptados y convenientes", al tiempo que se preservó la similitud con la imagen original.

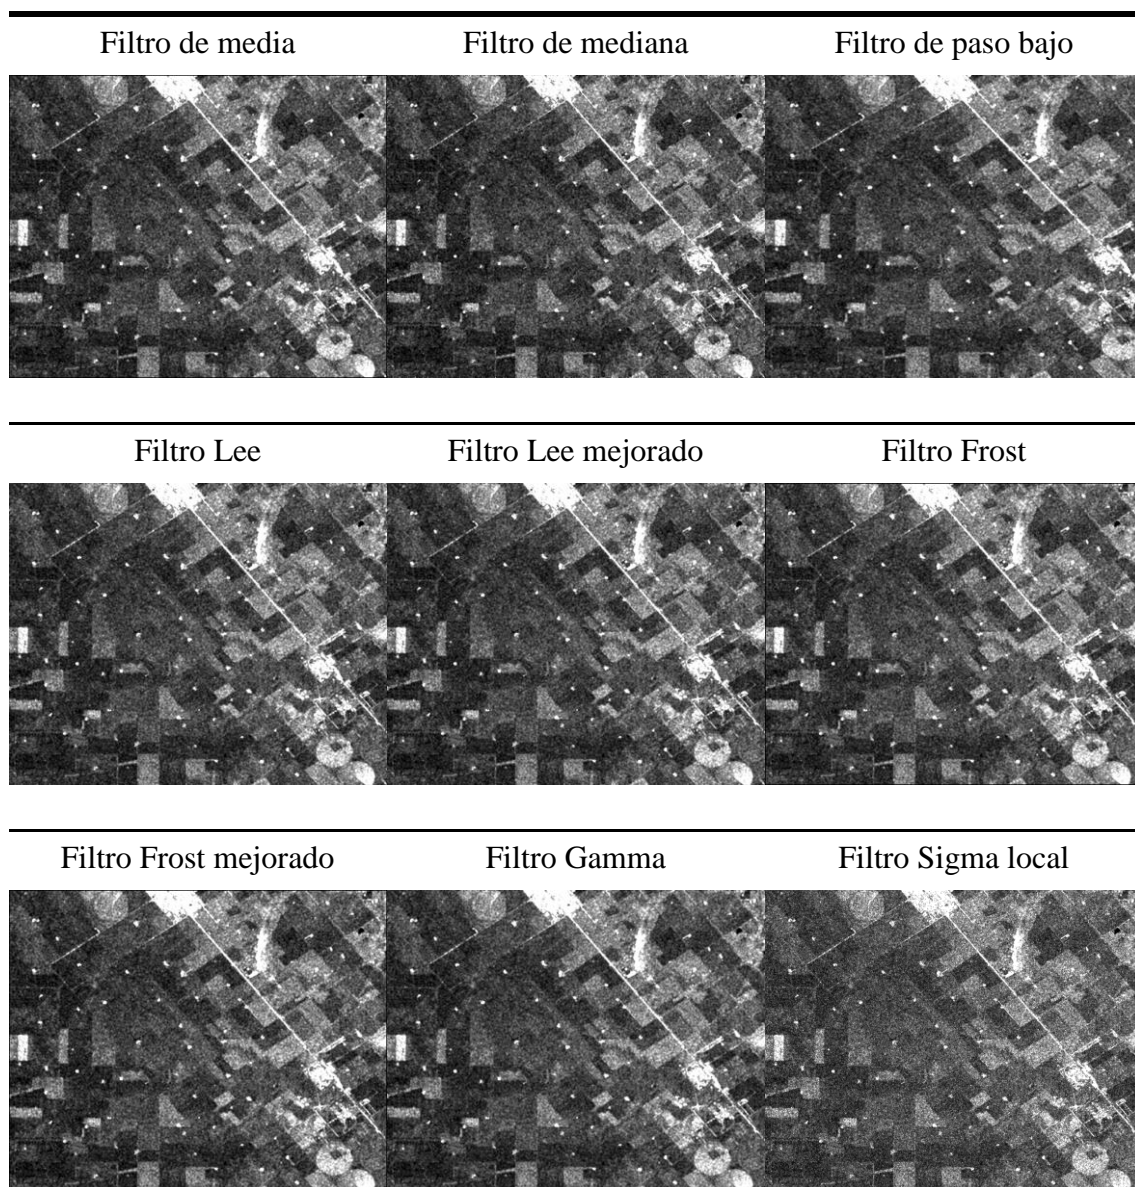


Figura 43. Recortes de las imágenes resultantes de aplicar los distintos filtros (imagen original: polarización HH, 31 agosto).

Análisis de la interacción de la onda según el tipo de rastrojo

Variación dentro y entre las clases de rastrojo⁹

En relación a los valores del coeficiente de retrodispersión (en decibeles), sobre las áreas con cobertura de rastrojo de maíz y soja, se demostró que los mismos cumplían con los requisitos de distribución del tipo normal (Apéndice B). Comprobado este supuesto, se elaboraron diagramas de caja a partir de los datos de retrodispersión para cada tipo de cobertura. Para ello se definieron 5 clases de cobertura del suelo; rastrojo de soja, rastrojo de soja con otros desechos vegetales (S-C), rastrojo de maíz, rastrojo de sorgo y suelo removido. Los gráficos suministran información sobre los valores mínimo y máximo, los cuartiles Q1, Q2 o mediana y Q3, y sobre la existencia de valores atípicos y la simetría de la distribución.

⁹ Debido al limitado número de lotes por clase, el análisis efectuado fue solo a modo exploratorio.

En los diagramas de caja de cada una de las parcelas en las bandas HH y VV (Figuras 44 y 45) es posible inferir una diferenciación según el tipo de rastrojo. La prueba de análisis de la varianza evidenció diferencias significativas entre clases de cobertura y entre los sitios. A través del test de Tukey, fue posible examinar estas diferencias para cada banda de polarización (Apéndice C). En estas salidas las comparaciones con un valor p-ajustado mayor que 0,05 indican que existen diferencias significativas entre las medias de los lotes contrastados. Al analizar estas salidas se verificó que es mínima la diferenciación entre los lotes con rastrojo de maíz y aquellos con rastrojo de soja, que presentaban aún restos de rastrojo de maíz de la campaña anterior, independientemente de la banda utilizada. La misma dificultad se manifiesta para discriminar lotes con rastrojo de soja del lote con rastrojo de sorgo. El análisis de los datos en polarización HH produce la misma tasa de error, que utilizando la polarización VV. Sin embargo, un mayor número de pares de lotes pertenecientes a la misma clase cobertura, fueron considerados "no diferentes" al usar los datos en polarización HH. En el análisis de los lotes con los datos en la polarización VV se determinaron diferencias entre lotes de la misma o diferente clase de cobertura. Trabajando con polarización HH, las medias de los valores de retrodispersión de los sitios con rastrojo de maíz no se consideran significativamente diferentes. Comportamiento similar ocurre con la clase de rastrojo de soja. El uso de los datos en la polarización HH logró una mejor diferenciación entre las clases que dentro de ellas (Figuras 46 y 47). Al respecto McNairn et al. (2001) trabajando con la banda C, comprobaron una correlación significativa entre los valores de retrodispersión en polarización HH y la cantidad de rastrojo de maíz, no así con en la polarización VV. La correlación fue positiva, indicando que aumentos en el porcentaje de coberturas de residuos resultaban en un mayor coeficiente de retrodispersión. En el mismo estudio reportaron que la retrodispersión entre lotes con suelo desnudo y lotes con rastrojo de maíz, era significativamente diferente usando la polarización HH a ángulos llanos. Esta diferenciación no era tan prometedora en la polarización VV. Para ángulos de incidencia mayores a 30° la polarización HH en la banda C es la que mejor correlaciona con la humedad del rastrojo de maíz, mientras que la relación con la humedad del suelo es insignificante (McNairn et al. 1997; McNairn et al. 1996).

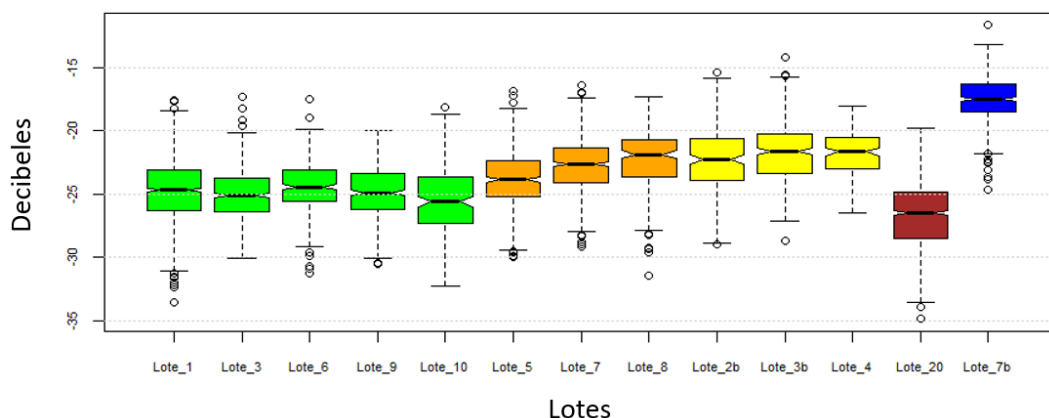


Figura 44. Diagramas de caja para los valores de retrodispersión (polarización HH) de los diversos lotes. Verde: rastrojo de soja, Amarillo: rastrojo de maíz, Naranja: rastrojo de soja con otros restos, Bordo: rastrojo de sorgo, Azul: suelo removido.




Figura 45. Diagramas de caja para los valores de retrodispersión (polarización VV) de los diversos lotes. Verde: rastrojo de soja, Amarillo: rastrojo de maíz, Naranja: rastrojo de soja con otros restos, Bordo: rastrojo de sorgo, Azul: suelo removido

Smith & Major (1996) trabajando con datos de radar en banda L, C y Ku, observaron que la retrodispersión en polarización HH a ángulos mayores de 30° fue sensible ante la presencia de residuos de cultivos mojados, mientras que la polarización VV no mostro diferencias significativas entre suelos con o sin residuos del cultivo en ningún ángulo o contenido de humedad. McNairn et al. (2002) señalan que la polarización VV es más sensible a los restos vegetales en pie.

Existe un consenso en que la intensidad de la retrodispersión en la polarización HH está fuertemente correlacionada con la rugosidad del suelo, en especial a ángulos de incidencia grandes. Con ángulos de incidencia pequeños (<30°), la correlación con el contenido de humedad de suelo es más fuerte (Adams, Berg, et al. 2013; Major et al. 1993). Comparando todas las polarizaciones en banda C, la precisión de predicción global más alta para humedad y rugosidad se obtiene con la polarización HH (McNairn et al. 1996). Este hecho se relaciona con la mayor rugosidad y contenido de humedad del rastrojo de maíz (McNairn et al. 1997), en relación al rastrojo de soja, bajo las mismas condiciones de humedad del suelo.

En los sitios identificados como Lote_7 y Lote_8 la presencia de remanentes de cultivo de maíz de campañas anteriores, pueden ser causantes de que los valores de retrodispersión en la polarización HH sean semejantes a la clase rastrojo de maíz. En el sitio Lote_20 los valores del coeficiente de retrodispersión son sutilmente diferentes respecto a las otras clases, esto podría deberse a la estructura de los residuos del cultivo de sorgo después de la cosecha, la cual se presenta con parte de los vástagos en pie. Por otro lado el sitio Lote_7b representa un suelo recién labrado, después de la cosecha de maní. La rugosidad y contenido de humedad de la superficie del suelo en este lote puede explicar el mayor valor del coeficiente de retrodispersión. Al mapear coberturas labradas a partir de radar, una mayor separabilidad de estas clases puede obtenerse inmediatamente después de la aplicación de la labranza, antes de que factores ambientales como la lluvia afecten la rugosidad del terreno (McNairn et al. 1996). Analizando diversos tipos de residuos de cultivos con imágenes SAR en banda C, (Adams, Rowlandson, et al. 2013; McNairn et al. 2002) encontraron una correlación estadísticamente significativa entre la intensidad de la retrodispersión en polarización HH y la rugosidad de la superficie. Para una mejor interpretación se muestran las imágenes de los principales arquetipos de rastrojos en la Figura 46.



Rastrojo de soja.

Rastrojo de maíz.

Rastrojo de sorgo.

Figura 46. Captura de los principales tipos de rastrojos en el área de estudio.

Estudio de discriminación de los tipos de residuo agrícola

A partir de la imagen del 31 de agosto, en polarización HH, procesada con filtro de Lee se computaron los estadísticos media y desvió estándar para dos sitios representativos de los tipos de residuos (Tabla 25). El primero poseía rastrojo de maíz, y el segundo rastrojo de soja sin presencia de residuos de otros cultivos. Con estos valores se calculó el número equivalente de looks (ENL), obteniendo como resultado un valor próximo a 8. A si mismo se observa que la diferencia en términos de la media de cada cobertura es de 3,3 decibelios. Al ingresar estos dos últimos valores en la tabla de intervalos de confianza (Apéndice D), se puede asegurar con un nivel de confianza del 95% que las 2 cubiertas son diferentes. Los residuos más grandes que proporcionan una mejor protección contra la erosión por el viento y el agua pueden separarse de residuos más finos (McNairn et al. 1998).

En las Figuras 47 y 48 se exponen los histogramas de frecuencia absoluta de los valores de retrodispersión (en decibeles) para áreas con cobertura de rastrojo de maíz y soja respectivamente. En la Figura 49 se comparan los dos histogramas en un mismo gráfico, se aprecia un patrón distintivo para cada tipo de cubierta. El valor medio de la clase rastrojo de maíz es mayor que el de rastrojo de soja. Este tipo de interacción puede ser adjudicada a la mayor cantidad y tamaño de los residuos de maíz. Como se mencionó en el marco teórico, las señales de radar interactúan con objetos de tamaño igual o más grande que la longitud de onda de la señal. El tamaño de los componentes del residuo de soja y maíz (en su mayor parte trozos de caña), poseen una dimensión semejante al valor de la longitud de onda de la banda X. Sin embargo el rastrojo procedente del cultivo de maíz, es considerablemente más abundante. Esto puede explicar las tres unidades de diferencia (en dB). Analizando residuos de cultivos con imágenes SAR en banda C McNairn et al. (1998) encontraron una correlación significativa y positiva entre porcentaje superficial de residuos de cultivos y el coeficiente de retrodispersión. El valor del coeficiente variaba 3-4 dB si se comparaban los retornos de suelos con alta y baja cobertura de residuos. Los bajos retornos en la señal de radar fueron resultado de la pequeña cantidad de cubierta de residuos y a la superficie del suelo lisa, condiciones asociadas a lotes de legumbres cosechados sin arar. Según McNairn et al. (2002) quienes trabajaron con banda C en suelos con abundantes rastrojos superficiales, pudieron determinar que el mecanismo de dispersión dominante es el volumétrico, por el contrario en lotes con residuos de cultivos esparcidos y muy finos, el mecanismo más imperante es la dispersión superficial, ya que los residuos pequeños tienen poco efecto en la respuesta del radar. Narayanan et al. (1992)

reportaron que no existe una correlación aparente entre la retrodispersión en polarización simple y los residuos de soja, pero si una respuesta positiva a los niveles de residuos de maíz.

Tabla 25. Medidas resumen filtro Lee 5x5 en decibeles (dB) e Intensidad (σ^0), para los estadísticos media, desvió estándar y número equivalente de looks, para los rastros de soja y maíz.

Tipo de rastrojo	Media (σ^0 dB)	Media (σ^0)	DE(σ^0)	NEL
Soja	-25.198068 dB	0,056093	0,018919	8,7906498442
Maíz	-21.866720 dB	0,083025	0,030338	7,4893456472
Diferencia (Valores absolutos)	3.331348 dB			

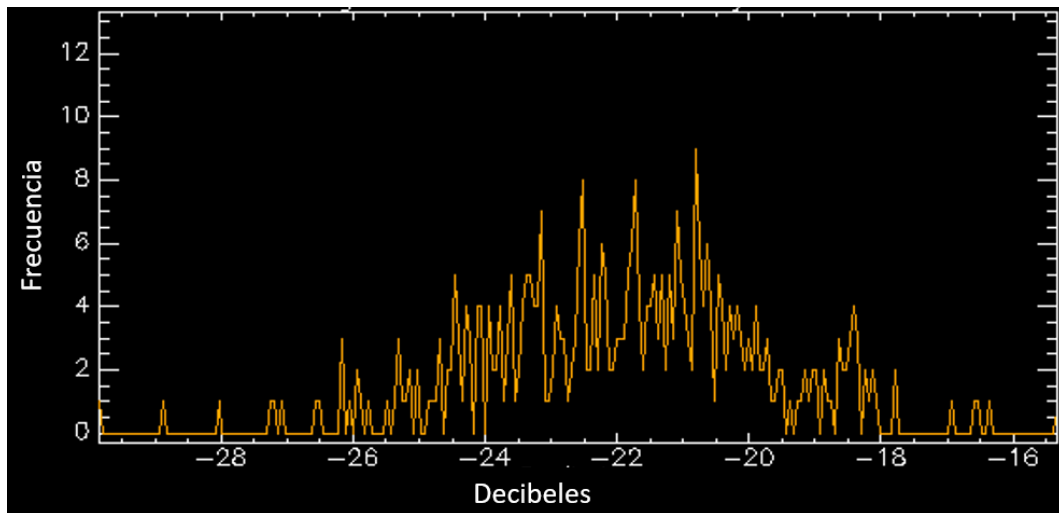


Figura 47. Histograma de valores de retrodispersión (dB) para un lote con rastrojo de maíz. 31 de agosto, polarización HH.




Figura 48. Histograma de valores de retrodispersión (dB) para un lote con rastrojo de soja. 31 de agosto, polarización HH.

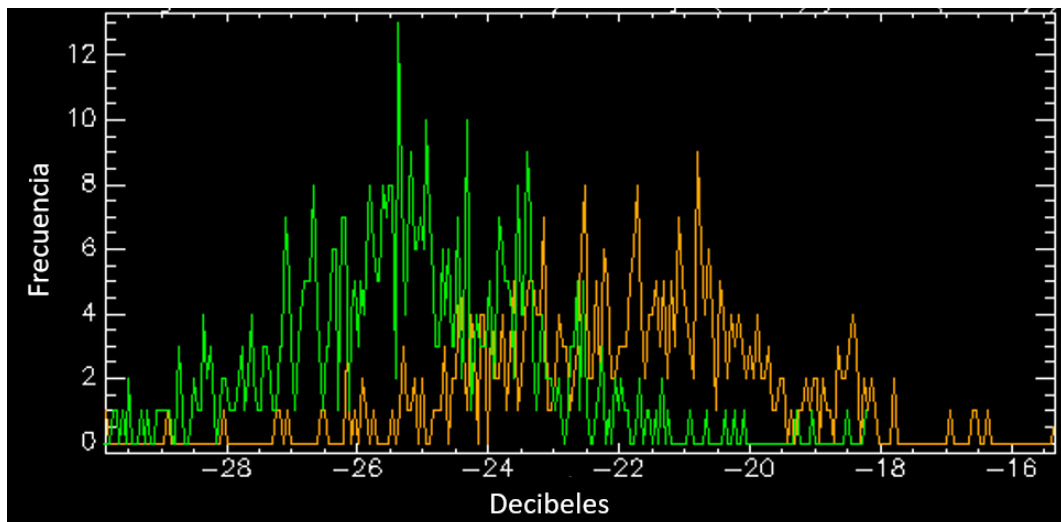


Figura 49. Histograma de valores de retrodispersión (dB) para los lotes con rastrojo de maíz (naranja) y soja (verde). 31 de agosto, polarización HH.

Análisis de la variación temporal de las clases representativas

Las Figuras 50, 51 y 52 se muestran los diagramas de caja para los valores del coeficiente de retrodispersión (polarización HH) de 3 sitios con rastrojo de maíz (Lote 2b, Lote 3b y Lote4, respectivamente). En las Figuras 53 y 54 se presentan los diagramas de caja para los sitios "Lote_3" y "Lote_5", respectivamente, los cuales presentaban rastrojo de soja. En total se procesaron imágenes de 7 fechas, cuya adquisición se efectuó entre la temporada post-cosecha (setiembre) y comienzo de la siembra de la nueva campaña (diciembre). El estudio se limitó a este periodo ya que en fechas posteriores la interacción de la señal puede incluir al dosel de los nuevos cultivos en crecimiento.




Figura 50. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_2b". Rastrojo de maíz, polarización HH.




Figura 51. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_3b". Rastrojo de maíz, polarización HH.




Figura 52. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_4". Rastrojo de maíz, polarización HH.




Figura 53. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_3". Rastrojo de soja, polarización HH.




Figura 54. Diagramas de caja para la dinámica temporal del coeficiente de retrodispersión en el sitio "lote_5". Rastrojo de soja, polarización HH.

Los gráficos precedentes no reflejan una tendencia temporal uniforme para los datos correspondientes a sitios con rastrojo de maíz y soja. Sin embargo pueden advertirse un aumento en los valores del coeficiente de retro dispersión de izquierda a derecha. Este comportamiento puede relacionarse con el comienzo de la temporada de lluvias en el área de estudio, lo cual implica mayores valores de humedad en los residuos sobre superficie y por consiguiente mayores valores del coeficiente de retrodispersión.

Para la imagen adquirida con fecha 26 de octubre de 2013, es posible apreciar un aumento en la retrodispersión en todos los lotes, esto puede relacionarse a un evento de precipitación ocurrido en la fecha de adquisición. En este punto hay que mencionar que poseer información sobre las condiciones del tiempo antes y al momento de la adquisición de los datos SAR, posibilita una mejor interpretación de las imágenes (Smith & Major 1996). La lluvia registrada en la estación meteorológica Pilar (-31,67 S, -63,85W) en los días previos a la fecha de adquisición, presumiría un aumento de las propiedades dieléctricas de la superficie del suelo. Se aprecia una concordancia en la dirección de movimiento de las nubes (imagen Landsat 8) y el patrón observado en la imagen SAR (Figura 55).




Figura 55. Imagen óptica (25/10/2013) y SAR (26/10/2013) sobre el área de estudio.

En relación a la lluvia y los eventos de rocío Smith & Major (1996) mencionan que estos acontecimientos pueden mejorar la retrodispersión del radar, posibilitando la separación de los suelos con cubiertas de residuos de suelos desnudos. Asimismo McNairn et al. (1998) expresan que adquisiciones de imágenes SAR durante periodos de alta humedad en los residuos, probablemente proporcionen la mejor separación entre las clases. Sin embargo, las imágenes precedentes demuestran que, si el evento no es uniforme, puede sucederse un efecto contrario, el cual dificulta e imposibilita la separación de las coberturas. Esta variabilidad puede disminuir a partir de los tres días posteriores si las condiciones de humedad son bajas (McNairn et al. 1996). Asimismo, la humedad del suelo en lotes con coberturas de residuos es más variable espacialmente, con respecto a suelos desnudos. En contraste temporalmente la humedad del suelo varía menos en lotes con residuos (McNairn et al. 1997).

Trabajando sobre la misma región que en el presente estudio, pero con los cultivos en etapas activas de su ciclo, Violini (2016) sugiere incluir múltiples fechas y ambas polarizaciones para

aumentar las precisiones de las clasificaciones a partir de imágenes SAR. Sin embargo es necesario combinar este tipo de imágenes con los de sensores ópticos si se quiere obtener resultados promisorios. Por otro lado los resultados de Holmes (1990) sugieren que la polarización cruzada puede ser más adecuada respecto a la polarización simple en la identificación de residuos de cultivos secos. Así mismo los cocientes HH/VV y HV/VV son sensibles a la rugosidad superficial. En especial el cociente HV/VV exhibe una dependencia más fuerte a la rugosidad, a la vez que es poco influenciado por el contenido de humedad (Oh et al. 1992). El porcentaje de cobertura por residuos está altamente correlacionado con varios parámetros del radar sensibles a la dispersión volumétrica o múltiple. Estos parámetros incluyen la polarización lineal cruzada, la co-polarización circular y altura del pedestal (McNairn et al. 2002). La polarización cruzada en banda C y L puede ser usada para discriminar prácticas de manejo de sitios con residuos de maíz. Para residuos más finos como el de cebada, menos clases pueden ser discriminadas. Los residuos de cebada son más chicos que las microondas de la banda L ($\approx 20\text{cm}$), lo cual sugiere una reducida sensibilidad a las características de este tipo de residuos (McNairn et al. 2001). Ante este hecho las imágenes en banda X en polarización cruzada pueden ser prometedoras, ya que su longitud de onda es de menor tamaño ($\approx 2.5\text{ cm}$). En el mismo sentido trabajando con banda C, McNairn et al. (2001) comprobaron que la polarización VH a ángulos de incidencia de 40 o 50° puede separar lotes con residuos agrícolas de aquellos con suelo desnudo independientemente de la dirección de mirada. La respuesta de este tipo de polarizaciones es resultado de la dispersión múltiple dentro del objetivo (McNairn et al. 1997). A futuro es interesante indagar en el potencial uso de otras polarizaciones.

En lo que respecta al mapeo de la humedad del suelo, los residuos de maíz poseen un efecto de máscara más acentuado, y consecuentemente es de esperar que la predicción del contenido de humedad en lotes cubiertos con residuos grandes como el de maíz alcance pobre resultados. La humedad propia del cultivo de maíz es el mayor contribuidor al coeficiente de retrodispersión cuando se trabaja con banda C (McNairn et al. 2001).

Clasificación

Los resultados de la evaluación de la precisión para la clasificación sobre el área 1, 2, 3 y 4, son detallados en las Tablas 27, 28, 29, y 30 respectivamente. Dentro de las tablas fueron resaltados los estadísticos Precisión del Productor (PP), Precisión del Usuario (PU) y estadístico Kappa (κ) que alcanzaron los máximos valores para cada clase de cobertura. Se aprecian resultados catalogados como buenos y muy buenos según la escala propuesta por Monserud & Leemans (1992), para las áreas de clasificación que agrupan imágenes de 2 y 3 fechas. Para estas áreas las precisiones globales y κ logrados al usar ambas polarizaciones (HH-VV), superaron a aquellos alcanzados con un único tipo de polarización. Este aumento de los índices de precisión es mayor en las clasificaciones que involucraron imágenes de 2 fechas contiguas en relación a la que incluyó imágenes de 3 fechas, también contiguas pero que abarcaban un periodo temporal más amplio. Los estadísticos que validan la clasificación que abarcaba 4 fechas, fueron los menores respecto a la que abarcaba 3. Estos resultados sugieren la necesidad de estudios más exhaustivos en el análisis multi-temporal de imágenes SAR, si se quieren obtener mejores precisiones.

Cuando se comparan los resultados de las clasificaciones que involucran imágenes de dos fechas, se aprecian mejores valores de los índices que validan la misma en los mapas generados a partir de las imágenes del mes de noviembre. Dichas mejoras pueden asociarse al aumento en el contenido de agua registrado en los rastrojos (Tabla 26), y por ende una mayor interacción de estos con la onda de radar (McNairn et al. 1997). Este comportamiento sugiere, que para lograr

separar coberturas por tipos de residuos pos cosecha, es crítico el contenido de humedad de los mismos. Más aún apartar del análisis las fechas en las que los valores de humedad son bajos, mejoran la separabilidad (McNairn et al. 2001). Esto último se observa en la clasificación del área 4, la cual posee datos de cuatro fechas, sin embargo, las precisiones alcanzadas son menores con respecto a la del área 3, que utiliza tres fechas en las que el rastrojo contenía más humedad.

Tabla 26. Porcentaje de humedad presente en el rastrojo de maíz (amarillo) y rastrojo de soja (verde) de los diferentes lotes registrados, según fecha de muestreo.

Lote	Momento de muestreo a campo					
	18 sep	9 oct	25 oct	6 nov	20 nov	3 dic
Lote 2	9,11	9,58				
Lote 3b			9,04	10,16	16,33	64,60
Lote 3	7,4	8,51	9,17	12,33	11,53	39,54
Lote 4	6,33	8,24	9,00	10,23	14,20	35,31
Lote 5	4,82	7,74	8,17	9,84	9,29	38,02

Respecto al proceso de regularización efectuado, en las cuatro áreas se observó un aumento de los estadísticos PG y κ posterior al empleo del filtro de mayoría. Estos mayores valores vaticinan oportunidades para el análisis con el enfoque orientado a objetos, ya que se podría sortear el problema de la mixtura de píxeles dentro de los lotes con cobertura homogénea. El incremento más significativo se aprecia para la clasificación realizada a partir de las imágenes del mes de noviembre, logrando valores de PG y κ de 82,65% y 0,72 respectivamente. Aunque en el momento de adquisición de las imágenes del área 2 (noviembre), los residuos de cultivos poseían los mayores valores de humedad, las precisiones de la clase rastrojo de maíz no exhibieron grandes aumentos. Para la zona de estudio en dicha época las condiciones ambientales empiezan a ser propicias para la siembra (Figura 56), como así también para la emergencia de malezas (Figura 57). Estos elementos pueden atentar contra una correcta clasificación, al modificar la interacción con la onda de radar y dificultar la observación de los efectos de los rastrojos sobre el coeficiente de retrodispersión (Smith & Major 1996). Al comparar los índices de precisión de cada clase para el área 1 y 2, se aprecia que los valores de Precisión del Productor de la clase rastrojo de maíz muestran pequeñas diferencias, en comparación a las clases rastrojo de soja y verdeo de invierno, cuyos índices aumentaron significativamente. Al analizar la matriz de confusión de dicha clasificación el mayor error ocurre en los píxeles de referencia de la clase rastrojo de maíz, que son clasificados como rastrojo de soja. Este hecho puede explicarse por el aumento en el coeficiente de retrodispersión que genera las operaciones de labranza (siembra directa) en los lotes con rastrojo de soja, y por ende cuando estos son utilizados en el entrenamiento pueden asemejarse en valores del coeficiente a los lotes con rastrojo de maíz sin roturar. Trabajando con imágenes SAR en banda C sobre lotes sin roturar o con diferentes niveles de roturación (Adams, Rowlandson, et al. 2013) observaron que es posible una confusión al contabilizar los campos con labranza de conservación ya que estos campos pueden ser físicamente similares tanto a la labranza cero (debido a la presencia de biomasa) como a la labranza convencional (debido a la rugosidad superficial).



Figura 56. Comienzo labores de siembra (imagen CNES/Airbus, adquirida el 15 de noviembre de 2013).




Figura 57. Estado de los lotes al momento del muestreo efectuado el 20 de noviembre de 2013.

Cuando se analizan los valores de los estadísticos PP, PU y κ de cada clase de cobertura para las áreas clasificadas, se observa que no siempre los mejores valores se encuentran en la clasificación que utiliza ambas polarizaciones. Diversos autores coinciden que los rastrojos son detectados de manera más eficiente si se utiliza polarización horizontal (Smith & Major 1996; McNairn et al. 2002; Adams, Berg, et al. 2013), mientras que la polarización vertical es más útil cuando se trabaja con elementos erguidos, como los cultivos de invierno en este trabajo. Sin embargo, para el caso de la clase rastrojo de maíz en el área 2, se obtuvieron estadísticos de validación levemente mejores al utilizar únicamente la polarización VV (Tabla 28). De manera semejante la clase verdeo de invierno solo registra mejores estadísticos al utilizar la polarización VV, respecto a la HH, cuando se trabajan con imágenes de 3 y 4 fechas (Tablas 29 y 30, respectivamente). Estos resultados pueden explicarse en la longitud de onda utilizada en el presente trabajo (banda X), cuya interacción es mejor con objetos de similar dimensión. El hecho de que se alcanzaron semejantes valores de los estadísticos al utilizar únicamente la banda HH con o sin la banda VV, e incluso valores superiores en la clasificación del área 4, reafirman la utilidad de los sensores en banda X, para el mapeo de superficies agrícolas que fueron utilizadas para el cultivo de legumbres en siembra directa. Trabajos que utilizan imágenes en banda L, aún con polarizaciones cruzadas, no detentaron diferencias significativas entre varios estados de

lotes con residuos de cebada (McNairn et al. 2001). Las señales transmitidas a longitudes de onda más largas tienden a penetrar más profundamente en la superficie del suelo y, por lo tanto, son menos sensibles a la presencia de residuos de cultivo. Como resultado, es probable que las longitudes de onda relativamente cortas de los sistemas SAR en banda X y C sean más efectivas (Zheng et al. 2014).

Tabla 27. Estadísticos de validación de la precisión de la clasificación en el área 1, según polarización utilizada. Se resaltan los mayores valores de los estadísticos para cada clase.

Clases	HH-VV			HH-VV filtro 5x5			HH			VV		
	PG (%)		κ	PG (%)		κ	PG (%)		κ	PG (%)		κ
	PP	PU	κ	PP	PU	κ	PP	PU	κ	PP	PU	κ
	63,72		0,44	70,82		0,55	59,99		0,38	58,86		0,33
rastrojo maíz	57	42	0,34	71	48	0,54	40	39	0,18	39	38	0,17
rastrojo soja	64	81	0,40	68	85	0,46	64	79	0,39	69	68	0,36
verdeo	70	66	0,60	77	83	0,70	72	53	0,60	59	62	0,47

Tabla 28. Estadísticos de validación de la precisión de la clasificación en el área 2, según polarización utilizada. Se resaltan los mayores valores de los estadísticos para cada clase.

Clases	HH-VV			HH-VV filtro 5x5			HH			VV		
	PG (%)		κ	PG (%)		κ	PG (%)		κ	PG (%)		κ
	PP	PU	κ	PP	PU	κ	PP	PU	κ	PP	PU	κ
	72,51		0,57	82,65		0,72	63,36		0,42	65,07		0,42
rastrojo maíz	58	86	0,41	70	93	0,55	49	70	0,31	65	84	0,47
rastrojo soja	88	72	0,76	96	77	0,91	89	69	0,76	86	57	0,65
verdeo	73	54	0,65	85	80	0,82	38	35	0,11	10	32	0,05

Tabla 29. Estadísticos de validación de la precisión de la clasificación en el área 3, según polarización utilizada. Se resaltan los mayores valores de los estadísticos para cada clase.

Clases	HH-VV			HH-VV filtro 5x5			HH			VV		
	PG (%)		κ	PG (%)		κ	PG (%)		κ	PG (%)		κ
	PP	PU	κ	PP	PU	κ	PP	PU	κ	PP	PU	κ
	75,66		0,58	81,36		0,68	73,01		0,53	71,87		0,52
rastrojo maíz	68	68	0,50	78	73	0,65	63	64	0,44	65	66	0,47
rastrojo soja	80	80	0,57	83	86	0,66	80	79	0,57	75	76	0,47
verdeo	82	79	0,79	82	91	0,79	71	72	0,67	77	70	0,74

Tabla 30. Estadísticos de validación de la precisión de la clasificación en el área 4, según polarización utilizada. Se resaltan los mayores valores de los estadísticos para cada clase.

Clases	HH-VV			HH-VV filtro 5x5			HH			VV		
	PG (%)		κ	PG (%)		κ	PG (%)		κ	PG (%)		κ
	PP	PU	κ	PP	PU	κ	PP	PU	κ	PP	PU	κ
	64,98		0,43	69,94		0,52	70,26		0,50	66,96		0,44
rastrojo maíz	56	49	0,31	64	53	0,41	48	55	0,28	49	52	0,27
rastrojo soja	67	83	0,41	69	90	0,46	80	81	0,57	76	76	0,47
verdeo	78	54	0,73	90	60	0,87	82	61	0,78	74	64	0,69

Cuando se analizan los resultados de la clase verdeo de invierno, los mejores resultados se observan en la clasificación que engloba imágenes de 3 fechas, seguidos por la que integra imágenes de 4 fechas (Tablas 29 y 30, respectivamente). Con respecto a las que utilizan imágenes adquiridas en dos fechas para el área 1 (situada al este de la ruta nacional número 9), no se observan grandes mejoras entre trabajar con una única polarización, o incluir al análisis ambas polarizaciones (Tabla 27). Sin embargo, para el área 2 (al oeste de la ruta nacional número 9), la cual trabaja con imágenes adquiridas en el mes de noviembre, existe una gran diferencia entre los índices obtenidos al utilizar una única polarización, respecto a los resultantes de utilizar ambas en conjunto (Tabla 28). Para el caso del índice Kappa, su valor se incrementa, desde los 0,11 (HH) y 0,05(VV) a un valor del 0,65 cuando se utilizan ambas polarizaciones. En el mes de noviembre los cultivos de invierno se encuentran en sus etapas finales de sus ciclos, para el caso del trigo su cosecha estaba próxima. Más aún para el año 2013, las condiciones de sequía que imperaron durante el ciclo de los cultivos de invierno, hizo disminuir temporalmente el ciclo de los mismos (Bolsa de Cereales de Córdoba 2013). Estos resultados sugieren la necesidad de trabajar con ambas polarizaciones cuando se desea mapear cultivos de invierno que se encuentran en etapas finales de sus ciclos. Así mismo es preferente mapear este tipo de cultivos, con imágenes adquiridas a lo largo de su ciclo de cultivo, o de la mayor parte del mismo (Tabla 29).

Por otra parte, es necesario mencionar el efecto de la topografía sobre la condición de los suelos. La presencia de pozos de infiltración y sus redes de drenaje asociadas (como las existentes en la parte este del área de análisis), pueden incorporar otra variable de importancia en la respuesta de la señal de radar. En estos sectores colindantes al Río Segundo, las parcelas agrícolas se encuentran en áreas ligeramente deprimidas, cuyos suelos se caracterizan por ser arenosódicos, imperfectamente drenados permaneciendo mojados por importantes lapsos de tiempo (Jarsún et al. 2003). El mayor contenido de humedad en el suelo de estos sectores, puede aumentar el valor de su constante dieléctrica, por lo cual los valores del coeficiente de retrodispersión dentro de un mismo lote con cultivo homogéneo, pueden diferir considerablemente en estas zonas.

Examen del mapeo operativo de coberturas de residuos agrícolas

Cuando se analizan las precisiones y coeficientes Kappa alcanzados en las áreas de clasificación 1, 2 y 3 que involucran ambas polarizaciones y su posterior filtrado, se aprecia que los mejores valores para cada tipo de cobertura son alcanzados en distintas áreas (Figura 58).

En el mapeo de las áreas con residuos de cultivo de maíz, mejores valores de los estadísticos de validación se obtienen en el área 3, la cual agrupa imágenes de tres fechas en el periodo octubre-noviembre. Para el caso de los lotes con rastrojo de soja se obtienen muy buenos índices en el área 2, lo cual sugiere que es mejor esperar el momento en que estos poseen más humedad, para su posterior detección. Por último, para las superficies con verdeo de invierno, es casi indistinto el momento de identificación. En la región analizada los lotes con verdeo de invierno alcanzaban sus mayores valores de NDVI en distintas fechas. Para próximos estudios las imágenes a utilizar podrían ser elegidas teniendo en cuenta el ciclo de cultivo del verdeo de invierno de interés, o generar sub-clases para esta categoría.

Según el propósito de estudio se podrían emplear los mapas generados próximos a la cosecha de los cultivos, para incluir una aproximación del efecto según el tipo de residuo sobre las estimaciones del contenido de humedad de los suelos. Aun cuando los mismos detentan bajas precisiones. Por otro lado, los mapas generados con imágenes próximas al inicio de la nueva campaña, los cuales detentan mejores precisiones en especial para la clase rastrojo de soja, pueden ser útiles en la estimación de áreas vulnerables a la erosión. Para el área de estudio estos mapas pueden ser generados con antelación a la época de eventos hídricos de gran milimetraje. Conocer la cuantía y localización de las superficies con escasa cobertura, como las que fueron cultivadas con soja, puede ser útil en la generación de planes de mitigación y contención de procesos erosivos.




Figura 58. PP, PU y κ alcanzados para cada tipo de cobertura en el área 1, 2 y 3

Por último el uso de polarización cruzada (HV – VH), es una alternativa en el mapeo de rastrojos, ya que pueden reducir el efecto de otras variables como el contenido de humedad y orientación de los surcos (Smith & Major 1996). Si por el contrario solo se dispone de datos SAR en polarización simple, la integración de estos datos con aquellos de origen óptico es necesario para alcanzar precisiones de clasificación aceptables (McNairn et al. 2009; Violini 2016).

Síntesis

En los últimos años se han adoptado ampliamente mejores prácticas de manejo agrícola, como lo es la labranza conservacionista y los cultivos de cobertura. Los beneficios de la labranza de conservación son sustanciales y se asocian a la acumulación de residuos de cultivos sobre la superficie del suelo. En este contexto la teledetección ofrece la oportunidad de obtener sistemáticamente información que describa las variables relacionadas con los cultivos agrícolas y los suelos. Más específicamente los sensores Radar de Apertura Sintética (SAR), ostentan la capacidad de sortear las condiciones de nubosidad, permitiendo complementar los datos provenientes de sensores ópticos.

En el presente capítulo se estudió la aplicabilidad de datos de radar de apertura sintética en el análisis de coberturas postcosecha, sobre la región centro de la provincia de Córdoba. En una primera instancia, se evaluaron diversos filtros específicos para la reducción del ruido speckle inherente a las imágenes de radar. Los resultados evidenciaron la conveniencia del uso de filtro Lee en el estudio de áreas agrícolas durante el periodo de barbecho. Dicho filtro preservó el valor medio del coeficiente de retrodispersión de áreas homogéneas. En lo que respecta al desvío estándar, este disminuía cuando la dimensión de la ventana de todos los filtros evaluados se incrementaba. El filtro Lee mantuvo valores más cercanos a la imagen original, indicando una mayor conservación de la información.

Posteriormente se realizó un análisis de la interacción señal - residuos agrícolas, haciendo hincapié en el potencial de discriminación. En general, el tamaño de los residuos relativo a la longitud de onda empleada, así como el contenido de humedad del residuo fueron clave en términos de la retrodispersión que presentaron los lotes agrícolas en el periodo de barbecho. El uso de los datos en la polarización HH logró una mejor diferenciación entre los sitios con rastrojo de soja y rastrojo de maíz, en comparación a los datos en polarización VV. En cuanto a los valores del coeficiente de retrodispersión, los sitios con rastrojo de soja presentaban valores bajos, los que poseían una mezcla de residuos de soja y maíz valores intermedios, mientras que los sitios con rastrojo de maíz valores más altos. Este comportamiento indicó un aumento del coeficiente de retrodispersión, ante la presencia de mayores cantidades de residuos. Al comparar los valores de NEL y diferencia absoluta en decibelios para dos sitios con cobertura homogénea de rastrojo de maíz y rastrojo de soja respectivamente, se demostró con un 95% de confianza, que las mismas eran disimiles.

Por último, se realizó un examen de la capacidad operativa de los sistemas SAR para el mapeo de coberturas de residuos agrícolas. En general las precisiones de los modelos que trabajaban con ambas polarizaciones superaron a los que trabajaban con una sola. Sin embargo, la inclusión de datos SAR de fechas en las que se registraron bajos valores de humedad en el rastrojo menguaba las precisiones de los mapas resultantes. Para el área de estudio los resultados del presente trabajo sugieren solicitar imágenes SAR de los meses de octubre y noviembre a fin de obtener las mejores precisiones en el mapeo de áreas con residuos de soja y maíz. Sin embargo, los mapas generados próximos al fin de las labores de cosecha, aunque son menos precisos, pueden ser utilizados para incluir el efecto del tipo de rastrojo en la estimación del contenido de humedad de los suelos. Por último, el proceso de regularización mejoró los índices de precisión, lo cual vaticina oportunidades para el análisis con el enfoque orientado a objetos.

Para próximos estudios se plantea:

- Evaluar la conveniencia de utilizar polarizaciones cruzadas en el mapeo de áreas con residuos agrícolas.
- Incluir en los estudios imágenes de sensores que trabajen en la banda C o L.
- Examinar la potencialidad de los datos SAR en el monitoreo de prácticas de labranza.
- Evaluar la implementación de estudios multitemporales de datos SAR para el mapeo de coberturas por rastrojo.

Capítulo 7

Conclusiones

La información sobre superficies dedicadas a cultivos agrícolas es fundamental para el cálculo de estimaciones de producción, conocer el riesgo de erosión de los suelos, y para mitigar las fluctuaciones en los suministros de alimentos. En el presente trabajo de tesis se evaluó la aplicabilidad de datos de sensores remotos pasivos y activos, en el mapeo de áreas agrícolas durante el periodo de cultivo y en momentos post cosecha. Los resultados de esta investigación proporcionan nuevos conocimientos sobre el desempeño de clasificadores paramétricos y no paramétricos, la posibilidad de extrapolar firmas espectrales y la aplicabilidad de datos radar en estudios sobre áreas agrícolas en el centro de la provincia de Córdoba, Argentina.

Con base a una metodología rigurosa de muestreo y registro de datos de campo, y posterior organización de la información a gabinete, se pudieron conformar clases de coberturas para cada cultivo y respectiva fase fenológica presente. La validación de la clasificación de los datos satelitales para la campaña agrícola 2015-2016, por medio de una única imagen de fines de temporada, demostró la efectividad de las variables espectrales de Landsat 8 para discriminar la variedad de cultivos presentes. La evaluación y comparación de los métodos de clasificación aquí presentados respaldan la conveniencia del algoritmo de Máxima Verosimilitud en el mapeo de cultivos agrícolas; el cual logra excelentes resultados en la discriminación de los cultivos por sus respectivos estadios fenológicos, es de ejecución sencilla y bajo costo computacional.

Cuando se analizaron los resultados de la validación de los mapas realizados con los algoritmos derivados del enfoque de aprendizaje automático, sobresale en primera instancia la capacidad del algoritmo SVM y RF para mantener buenos índices de precisión con los diversos grupos de clases de cultivos y coberturas no agrícolas. Estos superiores valores en los índices, pueden relacionarse con la capacidad del algoritmo SVM para detectar y superar las bandas ruidosas. Así mismo el gran impacto de la optimización de los parámetros C y γ en la precisión de la clasificación, permitió sortear el sobre entrenamiento y una pobre generalización. Con respecto al algoritmo RF, se evidenció su sensibilidad a la reducción en el conjunto de entrenamiento.

En cuanto a la extrapolación de firmas espectrales, los resultados evidenciaron la posibilidad de realizar mapas de áreas cultivadas con las especies soja y maíz, utilizando datos de referencia a campo de campañas agrícolas pasadas. En particular el momento de adquisición de los datos satelitales es crítico, las mayores precisiones se alcanzan al mapear dichos cultivos en estadios fenológicos próximos a la etapa floración. Así mismo en la realización de esta fase del estudio, se hicieron evidentes las falencias del enfoque de trabajo a nivel de pixel, en el cual la mixtura en el interior de los lotes hizo necesaria una posterior corrección. Este hecho promete oportunidades para el trabajo con el enfoque orientado a objetos, sin embargo los mejores resultados obtenidos con una segmentación previa, deben equilibrarse con el costo adicional de este proceso y los potenciales problemas de ajuste del algoritmo para grandes áreas.

Respecto a la evaluación de la aplicabilidad de datos de radar de apertura sintética en el análisis de coberturas post-cosecha, las pruebas de reducción del “ruido” speckle, determinaron que el filtro Lee el más apropiado para el problema en estudio, comparado a otros ocho filtros específicos para datos SAR. El filtro Lee fue el que mejor preservó el valor promedio y desvío estándar de las imágenes, en los cinco tamaños de ventana evaluados. Lo cual indica una mejor conservación del contenido de la información.

En lo que respecta a la discriminación de las clases de cobertura *rastrajo de soja* y *rastrajo de maíz*, el uso de los datos en la polarización HH logró una mejor diferenciación entre las mismas que dentro de ellas. El valor medio de la retrodispersión de la clase *rastrajo de maíz* fue mayor que la de *rastrajo de soja*. Este tipo de interacción puede ser adjudicada a la mayor cantidad y tamaño de los residuos del cultivo de maíz. El tamaño de los componentes del residuo de soja y maíz (en su mayor parte trozos de caña), poseen una dimensión semejante al valor de la longitud de onda de la banda X, lo cual explica en parte esta interacción. Cuando se analizaron las diferencias absolutas de los valores de retrodispersión y el NEL de la imagen, se pudo aseverar con un nivel de confianza del 95% que los dos tipos de coberturas eran diferentes.

Al analizar los mapas por tipo de cobertura post cosecha, se evidencio la utilidad de los datos SAR en banda X, en especial para identificar superficies agrícolas bajo siembra de monocultivo de soja. Para lograr la separación de las diversas clases es decisivo el contenido de humedad de los residuos. Por último cuando se desea mapear cultivos de invierno que se encuentran en etapas finales de sus ciclos se sugiere trabajar con ambas polarizaciones. Así mismo es preferente mapear este tipo de cultivos, con imágenes adquiridas a lo largo de su ciclo de cultivo, o de la mayor parte del mismo.

Perspectivas futuras

El presente trabajo de tesis brindó respuestas, como así también generó nuevos interrogantes y propuestas de trabajo, en lo que respecta al mapeo de áreas dedicadas a cultivos extensivos. Estas últimas pueden ser abordadas en futuras investigaciones, en especial referidas al estudio con conjuntos de clasificadores, series temporales y al uso de sensores de mayor resolución espacial, temporal y espectral. A continuación se presentan las principales líneas sobre las cuales sería interesante y provechoso, a nuestro criterio, realizar futuros estudios.

- Comparar el desempeño de distintos algoritmos y metodologías de segmentación en la generación de objetos conforme a la forma y tamaño de las parcelas de cultivo. Examinar el efecto por tipo de dato satelital e inclusión de datos vectoriales pre-existentes.
- Investigar los beneficios de utilizar conjuntos de algoritmos de clasificación, en el etiquetado de los datos. Comparar los enfoques pixel a pixel y el orientado a objetos.
- Indagar en los efectos de la cantidad y diversidad de clases a ingresar en los modelos.
- Dirigir los estudios de mapeo de cultivos, hacia análisis independientes para cada ZAH (dentro de la provincia de Córdoba). De esta forma poder considerar sus características únicas y mejorar el contraste entre las clases de cobertura.
- Analizar el desempeño del uso de datos SAR de mayores longitudes de onda y en polarización cruzada.
- Determinar la conveniencia de incluir variables auxiliares -de suelo, topográficas, climáticas- en los procesos de segmentación y clasificación.
- Realizar estudios multi-temporales de imágenes SAR, a fin de determinar las configuraciones más adecuadas en el mapeo de coberturas agrícolas pos cosecha.

Bibliografía

- Adams, J.R., Rowlandson, T.L., et al., 2013. Evaluating the Cloude–Pottier and Freeman–Durden scattering decompositions for distinguishing between unharvested and post-harvest agricultural fields. *Canadian Journal of Remote Sensing*, 39(4), pp.318–327.
- Adams, J.R., Berg, A.A., et al., 2013. Sensitivity of C-band SAR polarimetric variables to unvegetated agricultural fields. *Canadian journal of remote sensing*, 39(1), pp.1–16.
- Ali, S. & Smith-Miles, K.A., 2006. Improved support vector machine generalization using normalized input space. In *AI 2006: Advances in Artificial Intelligence*. Springer Berlin Heidelberg, pp. 362–371.
- Altieri, M.A. & Nicholls, C.I., 2013. Agroecología : única esperanza para la soberanía alimentaria y la resiliencia socioecologica. *Agroecología*, 7(2), pp.65–83.
- Alvarez, C., Alvarez, C.R. & Costantini, A., 2014. Carbon and nitrogen sequestration in soils under different management in the semi-arid Pampa (Argentina). *Soil & Tillage Research*, 142, pp.25–31.
- Andrade, F.H. et al., 1999. Kernel number determination in maize. *Crop Science*, 39(2), pp.453–459.
- Ariza, A., 2013. Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission).
- Aronoff, S., 2004. *Remote Sensing for GIS Managers*, Redlands: Esri Press.
- Arvor, D. et al., 2011. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. *International Journal of Remote Sensing*, 32(22), pp.7847–7871.
- Atzberger, C. et al., 2015. Agriculture. In *Land resources monitoring, modeling, and mapping with remote sensing*. pp. 71–112.
- Baatz, M. & Schäpe, A., 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In *Angewandte Geographische Informationsverarbeitung XII*. Karlsruhe, pp. 12–23.
- Badhwar, G.D., 1987. Landsat Classification of Argentina Summer Crops. *Remote Sensing of Environment*, 21, pp.111–117.
- Badhwar, G.D., Carnes, J.G. & Austin, W.W., 1982. Use of Landsat-Derived Temporal Profiles for Corn-Soybean Feature Extraction and Classification. *Remote Sensing of Environment*, 79(1), pp.57–79.
- Baigorri, H.E.J., *Criterios para la elección y el manejo de cultivares de soja*, Marcos Juárez. Available at: http://agro.unc.edu.ar/~ceryol/documentos/soja/Eleccion_cultivares.pdf.
- Ballard, D.H. & Brown, C.M., 1982. *Computer vision*, Englewood Cliffs: Prentice-Hall.
- Basanta, M. & Alvarez, C., 2015. Manejo sustentable de sistemas agrícolas en la región central de Córdoba : una experiencia de largo plazo en INTA EEA Manfredi. *Revista de investigaciones agropecuarias*, 41(2), pp.215–222.
- Becker-reshef, I. et al., 2010. Monitoring Global Croplands with Coarse Resolution Earth Observations: The Global Agriculture Monitoring (GLAM) Project. *Remote Sensing*, 2(6), pp.1589–1609.
- Benz, U.C. et al., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data

- for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3–4), pp.239–258.
- Blackburn, G.A., 1999. Relationships between spectral reflectance and pigment concentrations in stacks of deciduous broadleaves. *Remote Sensing of Environment*, 70(2), pp.224–237.
- Blaschke, T., 2006. Object based image analysis for automated information extraction – a synthesis i. In *MAPPS/ASPRS Fall Conference*. San Antonio, TX.
- Blaschke, T., 2005. Towards a framework for change detection based on image objects. *Göttinger Geographische Abhandlungen*, 113, pp.1–9. Available at: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:TOWARDS+A+FRAMEWORK+FOR+CHANGE+DETECTION+BASED+ON+IMAGE+OBJECTS#0>.
- Blaschke, T. & Strobl, J., 2001. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *GeoBIT/GIS*, 6(1), pp.12–17.
- Blough, R.F. et al., 1990. Runoff and erosion rates from slit, conventional, and chisel tillage under simulated rainfall. *Transactions-of-the-ASAE*, 33(5), pp.1557–1562.
- Bocco, M. et al., 2012. Estimating soybean ground cover from satellite images using neural-networks models. , 33(6), pp.1717–1728.
- Bocco, M. et al., 2007. Neural network models for land cover classification from satellite images. *Agricultura técnica*, 67(4), pp.414–421.
- Bocco, M., Sayago, S. & Willington, E., 2014. Neural network and crop residue index multiband models for estimating crop residue cover from Landsat TM and ETM + images. *International Journal of Remote Sensing*, 35(10), pp.3651–3663.
- Bolsa de cereales de Córdoba, 2016. Datos finales de producción. Available at: <http://www.bccba.com.ar/> [Accessed April 15, 2016].
- Bolsa de Cereales de Córdoba, 2013. *Informe N° 57 Situación de Cultivos Invernales*, Córdoba, Argentina. Available at: <http://www.bccba.com.ar/dia/info/informe-n-57situacion-cultivos-invernales-7305.html>.
- Bowker, D.E. et al., 1985. Spectral reflectances of natural targets for use in remote sensing studies. *NASA Reference Publication*.
- Breiman, L., 1996. Bagging predictors. *Machine Learning*, 24(2), pp.123–140. Available at: <http://link.springer.com/10.1007/BF00058655>.
- Breiman, L.E.O., 2001. Random Forests. *Machine Learning*, 45(1), pp.5–32.
- Brun, W.A., 1978. Assimilation. In A. G. Norman, ed. *Soybean physiology, agronomy, and utilization*. Academic Press, p. 45.
- Buemi, E., 2012. *Tratamiento de imágenes de radar de apertura sintética mediante filtros stack*. Universidad de Buenos Aires.
- Bullock, D.G., 1992. Crop rotation. *Critical Reviews in Plant Sciences*, 11(4), pp.309–326.
- Cabrera, A.L., 1976. Regiones fitogeográficas argentinas. *Enciclopedia Argentina de Agricultura y Jardinería*, p.85.
- Campos, M., 2008. Modelos zonales de producción en el Movimiento CREA. In AACREA, ed. *Producción de Soja*. Buenos Aires, pp. 99–148.
- Camps-Valls, G. et al., 2004. Robust support vector method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on Geoscience and Remote*

- Sensing*, 42(7), pp.1530–1542.
- Camps-Valls, G. et al., 2003. Support vector machines for crop classification using hyperspectral data. In Goos, G., J. Hartmanis, & J. van Leeuwen, eds. *Iberian Conference on Pattern Recognition and Image Analysis*. Springer, pp. 134–141.
- Canada Center for Remote Sensing, C.C. for M. and E.O., 2014. Fundamentals of Remote Sensing. Available at: <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9365> [Accessed August 9, 2016].
- Canty, M.J., 2014. *Image analysis, classification and change detection in remote sensing*, Crc Press.
- Casas, 2001. *La conservación de los suelos y la sustentabilidad de los sistemas agrícolas*,
- Chander, G. et al., 2009. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113(5), pp.893–903. Available at: <http://dx.doi.org/10.1016/j.rse.2009.01.007>.
- Chang, C.C. & Lin, C.J., 2001. LIBSVM: A Library for Support Vector Machines. Available at: <http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf> [Accessed October 7, 2016].
- Chappelle, E.W., Kim, M.S. & McMurtrey, J.E., 1992. Ratio Analysis of Reflectance Spectra (RARS): An Algorithm for the Remote Estimation of the Concentrations of Chlorophyll A, Chlorophyll B, and Carotenoids in Soybean Leaves. *Remote Sensing of Environment*, 39(3), pp.239–247.
- Chen, D., Huang, J. & Jackson, T.J., 2005. Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. *Remote Sensing of Environment*, 98, pp.225–236.
- Chuvieco, E., 2010. *Teledetección Ambiental. La observación de la Tierra desde el espacio*, Barcelona: Ariel.
- Cihlar, J., 2000. Land cover mapping of large areas from satellites: Status and research priorities. *International Journal of Remote Sensing*, 21(6–7), pp.1093–1114.
- Colwell, R.N. et al., 1983. *Manual of Remote Sensing - Interpretation and Applications*, Falls Church: American Society of Photogrammetry.
- Comaniciu, D. & Meer, P., 2002. Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5), pp.603–619.
- Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), pp.35–46.
- Covello, F. et al., 2010. COSMO-SkyMed an existing opportunity for observing the Earth. *Journal of Geodynamics*, 49(3–4), pp.171–180.
- Cristianini, N. & Shawe-Taylor, J., 2000. *An introduction to support vector machines*, Cambridge University Press.
- Cutler, D.R. et al., 2007. Random forests for classification in ecology. *Ecology*, 88(11), pp.2783–2792.
- Daughtry, C.S.T., 2001. Agroclimatology: Discriminating crop residues from soil by shortwave infrared reflectance. *Agronomy Journal*, 93(1), pp.125–131.
- Daza, C.G., 2009. *Zonas Agroeconómicas Homogéneas Córdoba*, Instituto Nacional de

Tecnología Agropecuaria.

- Di-Rienzo, J.A. et al., 2016. InfoStat versión 2016. Available at: www.infostat.com.ar.
- Duiker, S.W., 2011. Chapter 13: Effect of land use and soil management on soil properties and processes. In M. Shukla, ed. *Soil Hydrology, Land Use and Agriculture*. pp. 291–312.
- Edrosa, R.M., 2011. *Aplicación de la teledetección para el monitoreo de eventos hídricos superficiales mediante imágenes Cosmo Skymed*. Universidad Nacional de Córdoba.
- Endicott, S. et al., 2015. *Maíz Crecimiento y desarrollo, Iowa*.
- Erdas Inc, 1999. Erdas Field Guide.
- FAO, 2010. *The State of Food Insecurity in the World Addressing food insecurity in protracted crises*, Roma: Food and agriculture organization of the united nations.
- FAOSTAT, 2011. Land-use resources domain in FAOSTAT. *Food and Agriculture Organization of the United Nations, Rome, Italy*. Available at: <http://faostat.fao.org/site/678/DesktopDefault.aspx?PageID=678#ancor> [Accessed December 30, 2015].
- Fassio, A. et al., 1998. *Aspectos sobre fenología Tojo*, Montevideo: INIA.
- Fehr, W.R. & Caviness, C.E., 1977. *Stages of Soybean Development*,
- Foley, J. a. et al., 2011. Solutions for a cultivated planet. *Nature*, 478, pp.337–342.
- Foody, G.M., 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80, pp.185–201.
- Foody, G.M. et al., 2006. Training set size requirements for the classification of a specific class. *Remote Sensing of Environment*, 104(1), pp.1–14.
- Foody, G.M. & Mathur, J., 2004. A relative evaluation of multiclass image classification by support vector machines. *IEEE Trans. Geosci. Rem. Sens*, 42(6), pp.1–9.
- Formaggio, A.R., Vieira, M.A. & Renno, C.D., 2012. Object Based Image Analysis (OBIA) and Data Mining (DM) in Landsat time series for mapping soybean in intensive agricultural regions. In *International Geoscience and Remote Sensing Symposium (IGARSS)*. pp. 2257–2260.
- Freund, Y., 1995. Boosting a weak learning algorithm by majority. *Information and computation*, 121(2), pp.256–285.
- Freund, Y. & Schapire, R.R.E., 1996. Experiments with a New Boosting Algorithm. *International Conference on Machine Learning*, pp.148–156. Available at: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.51.6252>.
- Frulla, L. et al., 1998. Metodologías de Pre-procesamiento y Procesamiento Utilizadas en el Tratamiento Cuantitativo de Datos SAR Para el Estudio de Ambientes en el Bajo Delta del Río Paraná, Argentina. *Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brasil*, pp.1–12. Available at: papers2://publication/uuid/F493F8AC-B9EE-47D4-AD1A-759A205D4E77.
- Gagnon, L. & Jouan, A., 1997. Speckle filtering of SAR images: a comparative study between complex-wavelet-based and standard filters. *Optical Science, Engineering and Instrumentation*, pp.80–91.
- Gausman, H.W., 1974. Leaf reflectance of near-infrared. *Photogrammetric Engineering*, 40(2).

- Gelder, B.K., Kaleita, A.L. & Cruse, R.M., 2009. Estimating mean field residue cover on midwestern soils using satellite imagery. *Agronomy Journal*, 101(3), pp.635–643.
- Geneletti, D. & Gorte, B.G.H., 2003. A method for object-oriented land cover classification combining Landsat TM data and aerial photographs. *International Journal of Remote Sensing*, 24(6), pp.37–41.
- Gitelson, A.A., Peng, Y. & Huemmrich, K.F., 2014. Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250 m resolution data. *Remote Sensing of Environment*, 147, pp.108–120. Available at: <http://dx.doi.org/10.1016/j.rse.2014.02.014>.
- Glenn, N.F. & Carr, J.R., 2003. The use of geostatistics in relating soil moisture to RADARSAT-1 SAR data obtained over the Great Basin, Nevada, USA. *Computers & Geosciences*, 29(5), pp.577–586.
- Gonzalez, R.C. & Woods, R.E., 2002. *Digital Image Processing*, Delhi: Pearson Education.
- Gorgas, J., Red de información agro económica de la región pampeana (RIAN). Zonificación del Proyecto. Área Córdoba. *Boletín informativo de la provincia de Córdoba*, 1.
- Guerschman, J.P. et al., 2003. Land cover classification in the Argentine Pampas using multi-temporal Landsat TM data. *International Journal of Remote Sensing*, 24(17), pp.3381–3402.
- Gutiérrez Angonese, J. & Grau, H.R., 2014. Assessment of swaps and persistence in land cover changes in a subtropical periurban region, NW Argentina. *Landscape and Urban Planning*, 127, pp.83–93.
- Hastie, T.J., Tibshiran, R.J. & Friedman, J.H., 2001. *The elements of statistical learning: data mining, inference, and prediction*, Berlin: Springer series in statistics.
- Henderson, F.M. & Lewis, A.J., 1998. Principles and applications of imaging radar. In *Manual of remote sensing*.
- Hofmann, M., 2006. *Support Vector Machines — Kernels and the Kernel Trick*,
- Hofmann, P., 2001. Detecting buildings and roads from IKONOS data using additional elevation information. *GeoBIT/GIS*, 6(1), pp.28–33.
- Holmes, M.G., 1990. Applications of radar in agriculture. In *Applications of Remote Sensing in Agriculture*. pp. 307–330.
- Hossain, M.S. et al., 2015. Assessment of Landsat 7 Scan Line Corrector-off data gap-filling methods for seagrass distribution mapping. *International Journal of Remote Sensing*, 36(4), pp.1188–1215.
- Hsu, C.W., Chang, C.C. & Lin, C.J., 2003. A practical guide to support vector classification.
- Huang, C., Davis, L. & Townshend, J., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), pp.725–749.
- INDEC, Censo Agropecuario 2008. *Cuadros estadísticos*. Available at: http://www.indec.gov.ar/nivel4_default.asp?id_tema_1=3&id_tema_2=8&id_tema_3=87 [Accessed May 12, 2017].
- Jackson, T.J. et al., 2004. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sensing of Environment*, 92, pp.475–482.

- Janssen, L.L.F., 1994. *Methodology for Updating Terrain Object Data from Remote Sensing Data*. Landbouw Universiteit Wageningen.
- Jarsún, B. et al., 2003. *Recursos naturales de la provincia de Córdoba, los suelos: nivel de reconocimiento escala 1: 500.000.*, Agencia Córdoba DAC y TSEM Dirección Ambiente y Instituto Nacional de Tecnología Agropecuaria INTA-Manfredi.
- Jia, K. et al., 2014. Land Cover Classification of Landsat Data with Phenological Features Extracted from Time Series MODIS NDVI Data. *Remote Sensing*, 6, pp.11518–11532.
- Jia, K. et al., 2014. Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China. *Geocarto International*, 29(8), pp.941–951.
- Jordan, M.I. & Thibaux, R., 2004. The Kernel Trick. , pp.1–4.
- Kavzoglu, T. & Colkesen, I., 2009. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), pp.352–359.
- Keuchel, J. et al., 2003. Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data. *Remote Sensing of Environment*, 86, pp.530–541.
- Kim, H. et al., 2003. Constructing support vector machine ensemble. *Pattern Recognitio*, 36, pp.2757–2767.
- King, R.B., 2010. Land cover mapping principles : A return to interpretation fundamentals. *International Journal of Remote Sensing*, 23(18), pp.37–41.
- Kohavi, R. & Provost, F., 1998. Glossary of Terms. *Machine Learning*, pp.271–274. Available at: <http://ai.stanford.edu/~ronnyk/glossary.html> [Accessed March 3, 2016].
- Kornelsen, K.C. & Coulibaly, P., 2013. Advances in soil moisture retrieval from synthetic aperture radar and hydrological applications. *Journal of Hydrology*, 476, pp.460–489. Available at: <http://dx.doi.org/10.1016/j.jhydrol.2012.10.044>.
- Langley, P. & Simon, H.A., 1981. The central role of learning in cognition. *Cognitive skills and their acquisition*, pp.361–380.
- Laur, H. et al., 2004. DERIVATION of the BACKSCATTERING COEFFICIENT σ_0 in ESA ERS SAR PRI PRODUCTS. *ERS SAR calibration*, (2).
- Leconte, R. et al., 2004. Mapping near-surface soil moisture with RADARSAT-1 synthetic aperture radar data. *Water Resources Research*, 40(1).
- Lee, J.S. et al., 1994. Speckle filtering of synthetic aperture radar images: A review. *Remote Sensing Reviews*, 8(4), pp.313–340. Available at: <http://www.tandfonline.com/doi/abs/10.1080/02757259409532206>.
- Leteinturier, B., Herman, J.L. & Longueville, F. De, 2006. Adaptation of a crop sequence indicator based on a land parcel management system. *Agriculture Ecosystems & Environment*, 112, pp.324–334.
- Lillesand, T., Kiefer, R.W. & Chipman, J., 2004. *Remote sensing and image interpretation*, John Wiley & Sons.
- Long, J.A. et al., 2013. Object-oriented crop classification using multitemporal ETM + SLC-off imagery and random forest. *GIScience & Remote Sensing*, 50(4), pp.418–436.
- Lopes, A., Touzi, R. & Nezry, E., 1990. Adaptive Speckle Filters and Scene Heterogeneity. *IEEE transactions on Geoscience and Remote Sensing*, 28(6), pp.992–1000.

- Löw, F. et al., 2013. Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using Support Vector Machines. *ISPRS Journal of Photogrammetry and Remote Sensing*, 85, pp.102–119.
- Lozano, L.A. et al., 2014. Stabilization of soil hydraulic properties under a long term no-till system. *Revista Brasileira de Ciência do Solo*, 38(4), pp.1281–1292.
- Lu, D. & Weng, Q., 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), pp.37–41.
- MacRae, R.J. & Mehuys, G.R., 1985. The effect of green manuring on the physical properties of temperate-area soils. In *Advances in soil science*. New York: Springer, pp. 71–94.
- Major, D.J. et al., 1993. Tillage effects on radar backscatter in southern Alberta. *Canadian journal of remote sensing*, 19(2), pp.170–176.
- Maling, D.H., 1989. *Measurements from maps: principles and methods of cartometry*, Oxford: Pergamon Press.
- Mansourpour, M., Rajabi, M. & Blais, R., 2006. Effects and Performance of Speckle Noise Reduction Filters on Active Radar and SAR Images. In *ISPRS*.
- Mather, P.M., 2011. *Computer Processing of Remotely-Sensed Images*, West Sussex, England: John Willey and Sons Ltd.
- Mathur, A. & Foody, G.M., 2008. Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29(8), pp.2227–2240.
- Matton, N. et al., 2015. An automated method for annual cropland mapping along the season for various globally-distributed agrosystems using high spatial and temporal resolution time series. *Remote Sensing*, 7(10), pp.13208–13232.
- McNairn, H. et al., 2012. Monitoring Soil Moisture to Support Risk Reduction for the Agriculture Sector Using RADARSAT-2. *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(3), pp.824–834.
- McNairn, H. et al., 2001. Defining the Sensitivity of Multi-Frequency and Multi-Polarized Radar Backscatter to Post-Harvest Crop Residue. *Canadian Journal of Remote Sensing*, 27(3), pp.247–263.
- McNairn, H. et al., 2014. Early season monitoring of corn and soybeans with TerraSAR-X and RADARSAT-2. *International Journal of Applied Earth Observation and Geoinformation*, 28(1), pp.252–259. Available at: <http://dx.doi.org/10.1016/j.jag.2013.12.015>.
- McNairn, H. et al., 1996. Identification of agricultural tillage practices from C-band radar backscatter. *Canadian Journal of Remote Sensing*, 22(2), pp.154–162.
- McNairn, H. et al., 2009. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), pp.434–449. Available at: <http://dx.doi.org/10.1016/j.isprsjprs.2008.07.006>.
- McNairn, H. et al., 1997. Investigating the Relationship Between Crop Residue Cover and Radar Backscatter. *Geomatics in the Era of RADARSAT*.
- McNairn, H. et al., 1998. Mapping Tillage and Crop Residue Management Practices with RADARSAT. *Canadian Journal of Remote Sensing*, 24(1), pp.28–35.

- McNairn, H. et al., 2002. The effect of soil and crop residue characteristics on polarimetric radar response. *Remote Sensing of Environment*, 80(2), pp.308–320.
- Miller, F.P., 2008. After 10,000 Years of Agriculture, Whither Agronomy? *Agronomy journal*, 100(1), pp.22–34.
- Ministerio de Agroindustria de la Nación, Datos abiertos de agroindustria. *Producción estimaciones*. Available at: <https://datos.magyp.gob.ar/reportes.php?reporte=Estimaciones> [Accessed August 10, 2016].
- Monserud, R.A. & Leemans, R., 1992. Comparing global vegetation maps with the Kappa statistic. *Ecological Modelling*, 62(4), pp.275–293.
- Morón, A., 2004. Efecto de las rotaciones y el laboreo en la calidad del suelo. *INIA Actividad de difusión 365*, pp.7–10. Available at: <http://www.inia.uy/Publicaciones/Documentos/compartidos/111219220807100737.pdf#page=9>.
- Mountrakis, G., Im, J. & Ogole, C., 2011. Support vector machines in remote sensing : A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), pp.247–259. Available at: <http://dx.doi.org/10.1016/j.isprsjprs.2010.11.001>.
- Muller, K.R. et al., 2001. An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, 12(2), pp.181–201.
- Murai, S., 1993. Remote Sensing Note.
- Murthy, C.S., Raju, P. V. & Badrinath, K.V.S., 2003. Classification of wheat crop with multi-temporal images : performance of maximum likelihood and artificial neural networks. *International Journal of Remote*, 24, pp.4871–4890.
- Narayanan, R.M., Mielke, L.N. & Dalton, J.P., 1992. Crop residue cover estimation using radar techniques. *Applied Engineering in Agriculture*, 8(6), pp.863–869.
- National Aeronautics and Space Administration, 2002. NASA's Land Cover Land Use Change (LULCC) Program. Available at: <http://lcluc.umd.edu/index.php> [Accessed March 4, 2016].
- National Research Council (NRC), 2001. *Grand Challenges in Environmental Sciences*, Washington, DC: National Academy Press.
- Naylor, R., 2011. Expanding the boundaries of agricultural development. *Food Security*, 3(2), pp.233–251.
- Nitze, I. & Schulthess, U., 2012. Comparison of machine learning algorithms random forest , artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. In *4th GEOBIA*. Rio de Janeiro, pp. 35–40.
- Nolasco, M., Willington, E. & Bocco, M., 2016. Uso del suelo agrícola: comparación entre series temporales e imágenes satelitales individuales para su clasificación. *Revista de Investigaciones de la Facultad de Ciencias Agrarias-UNR*, 26, pp.017–021.
- Van Oevelen, P.J., 1998. Soil moisture variability : a comparison between detailed field measurements and remote sensing measurement techniques. *Hydrological Sciences Journal*, 43(4), pp.511–520.
- Oh, Y., 2008. Effect of standing stubble on radar backscatter from harvested rice fields. *Electronics Letters*, 44(24), pp.1423–1424.
- Oh, Y., Sarabandi, K. & Ulaby, F.T., 1992. An Empirical Model and an Inversion Technique for Radar Scattering from Bare Soil Surfaces. *IEEE transactions on Geoscience and Remote*

- Sensing*, 30(2), pp.370–381.
- Ok, A.O., Akar, O. & Gungor, O., 2012. Evaluation of random forest method for agricultural crop classification. *European Journal of Remote Sensing*, 45(3), pp.421–432.
- Oliver, C. & Quegan, S., 2004. *Understanding synthetic aperture radar images*, SciTech Publishing.
- OTB Team, 2016. *The Orfeo ToolBox Cookbook, a guide for non-developers*, Centre National d'Études Spatiales. Available at: <https://www.orfeo-toolbox.org/packages/OTBCookBook.pdf>.
- Otukey, J.R. & Blaschke, T., 2010. Land cover change assessment using decision trees , support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, pp.27–31.
- Di Pace, M., 1992. *Las utopias del medio ambiente: desarrollo sustentable en Argentina* Centro editor de America latina, ed., Bibliotecas Universitarias.
- Pacheco, A. & McNairn, H., 2010. Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping. *Remote Sensing of Environment*, 114(10), pp.2219–2228. Available at: <http://dx.doi.org/10.1016/j.rse.2010.04.024>.
- Pal, M. & Mather, P.M., 2005. Support vector machines for classification in remote sensing. *International Journal of Remote*, 26(5), pp.1007–1011.
- Pampaloni, P. et al., 2004. *Radar Remote Sensing of Soil Moisture*,
- Panda, S.S. et al., 2015. Remote Sensing Systems—Platforms and Sensors: Aerial, Satellite, UAV, Optical, Radar, and LiDAR. In P. S. Thenkabail, ed. *Remotely Sensed Data Characterization, Classification, and Accuracies*. CRC Press, pp. 3–58.
- De Paul, O.V., 2012. Review Article : Remote Sensing , Surface Residue Cover and Tillage Practice. *Journal of Environmental Protection*, 2012(February), pp.211–217.
- Pelletier, N. & Tyedmers, P., 2010. Forecasting potential global environmental costs of livestock production 2000 – 2050. *Proceedings of the National Academy of Sciences*, 107(43), pp.18371–18374.
- Peña-barragán, J.M. et al., 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6), pp.1301–1316. Available at: <http://dx.doi.org/10.1016/j.rse.2011.01.009>.
- Peña, M.A. & Brenning, A., 2015. Assessing fruit-tree crop classification from Landsat-8 time series for the Maipo Valley , Chile. *Remote Sensing of Environment*, 171, pp.234–244. Available at: <http://dx.doi.org/10.1016/j.rse.2015.10.029>.
- Pierce, F.J. & Rice, C.W., 1988. Crop rotation and its impact on efficiency of water and nitrogen use. In W. L. Hargrove, ed. *Cropping strategies for efficient use of water and nitrogen*. American Society of Agronomy, pp. 21–42.
- Plourde, J.D., Pijanowski, B.C. & Pekin, B.K., 2013. Agriculture , Ecosystems and Environment Evidence for increased monoculture cropping in the Central United States. *"Agriculture, Ecosystems and Environment"*, 165, pp.50–59. Available at: <http://dx.doi.org/10.1016/j.agee.2012.11.011>.
- Porter, P.M. et al., 1997. Environment Affects the Corn and Soybean Rotation Effect. *Agronomy journal*, 89(3), pp.442–448.
- Potter, K.N. et al., 1997. Crop rotation and tillage effects on organic carbon sequestration in

- the semiarid southern great plains. *Soil Science*, 162(2), pp.140–147.
- Potter, K.N., Torbert, H.A. & Morrison, J.E.J., 1995. Tillage and residue effects on infiltration and sediment losses on Vertisols. *Am. Soc. Agr. Eng.*, 38(5), pp.1413–1419.
- Ravelo, A. et al., 2011. Evaluación de la desertificación a nivel Nacional. In *Evaluación de la desertificación en Argentina*. Buenos Aires, pp. 77–97.
- Reddy, G.S. et al., 2001. Influence of plant pigments on spectral reflectance of maize , groundnut and soybean grown in semi-arid environments. *International Journal of Remote Sensing*, 22(17), pp.3373–3380.
- Richards, J.A., 2013. *Remote Sensing Digital Image Analysis*, New York: Springer.
- Ritchie, S.W. & Hanway, J.J., 1982. *How a corn plant develops*,
- Roberts, L.G., 1963. *Machine perception of three-dimensional solids*. Massachusetts Institute of Technology.
- Rodriguez-Galiano, V.F., Ghimire, B., et al., 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(1), pp.93–104. Available at: <http://dx.doi.org/10.1016/j.isprsjprs.2011.11.002>.
- Rodriguez-Galiano, V.F., Chica-olmo, M., et al., 2012. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*, 121, pp.93–107. Available at: <http://dx.doi.org/10.1016/j.rse.2011.12.003>.
- Rodriguez-Galiano, V.F. & Chica-Rivas, M., 2012. Evaluation of different machine learning methods for land cover mapping of a Mediterranean area using multi-seasonal Landsat images and Digital Terrain Models. *International Journal of Digital Earth*, (November 2015), pp.1–18. Available at: <http://dx.doi.org/10.1080/17538947.2012.748848>.
- Rubiolo, O.J. et al., 2006. *Herramientas básicas para ajustar la tecnología del cultivo de maíz en la región central de Córdoba*, Córdoba.
- Sahajpal, R. et al., 2014. Identifying representative crop rotation patterns and grassland loss in the US Western Corn Belt. *COMPUTERS AND ELECTRONICS IN AGRICULTURE*, 108, pp.173–182. Available at: <http://dx.doi.org/10.1016/j.compag.2014.08.005>.
- Salado-Navarro, L.R., Sinclair, T.R. & Morandini, M., 2012. Estimation of Soil Evaporation During Fallow Seasons to Assess Water Balances for No-Tillage Crop Rotations. *Journal of Agronomy and Crop Science*, pp.1–9.
- Salvia, M.M., 2010. *Aporte de la teledetección al estudio del funcionamiento del macrosistema Delta del Paraná: Análisis de series de tiempo y eventos extremos*.
- Van der Sande, C.J., De Jong, S.M. & De Roo, A.P.J., 2003. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation*, 4(3), pp.217–229.
- Sanzano, G.A. et al., 2008. Efecto de la cobertura de rastrojos y las propiedades edáficas superficiales sobre la erosión hídrica en monocultivo de soja. *Revista Industrial y Agrícola de Tucumán*, 85(1), pp.23–30.
- Scholz, D. et al., 1979. *Evaluation of several schemes for classification of remotely sensed data: Their parameters and performance*, Indiana. Available at:

- <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19800015241.pdf>.
- Schott, J.R., 2007. *Remote Sensing: The Image Chain Approach*, New York: Oxford University Press.
- Schowengerdt, R.A., 2007. *Remote Sensing: Models and Methods for Image Processing*, Chicago: Academic Press.
- Schreier, G., 1993. Geometrical properties of SAR images. *SAR geocoding: Data and Systems*, pp.103–134.
- Schultz, B. et al., 2015. Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil. *Remote Sensing*, 7(11), pp.14482–14508.
- Senay, G.B. et al., 2000. Using High Spatial Resolution Multispectral Data to Classify Corn and Soybean Crops. *Photogrammetric Engineering and Remote Sensing*, (March), pp.319–327.
- Shaw, G.A. & Burke, H.H., 2003. Spectral imaging for remote sensing. *Lincoln Laboratory Journal*, 14(1), pp.3–28.
- Simon, P., 2013. *Too Big to Ignore: The Business Case for Big Data* John Wiley & Sons., ed., Wiley.
- Sims, D. & Gamon, J., 2002. Relationship between leaf pigment content and spectral reflectance across a wide range species, leaf structures and development stages. *Remote Sensing of Environment*, 81, pp.337–354.
- Slaton, M.R., Hunt, E.R. & Smith, W.K., 2001. Estimating near-infrared leaf reflectance from leaf structural characteristics. *American Journal of Botany*, 88(2), pp.278–284.
- Smith, A.M. & Major, D.J., 1996. Radar backscatter and crop residues. *Canadian Journal of Remote Sensing*, 22(3), pp.243–247.
- Stoner, E.R. & Baumgardner, M.F., 1981. Characteristic variations in reflectance of surface soils. *Soil Science Society of America Journal*, 45(6), pp.1161–1165.
- Tatsumi, K. et al., 2015. Crop classification of upland fields using Random forest of time-series Landsat 7 ETM + data. *Computers and Electronics in Agriculture*, 115, pp.171–179. Available at: <http://dx.doi.org/10.1016/j.compag.2015.05.001>.
- Tilman, D. et al., 2002. Agricultural sustainability and intensive production practices. *Nature*, 418(6898), pp.671–677.
- Tilton, J.C., 1989. Image segmentation by iterative parallel region growing and splitting. In *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS)*. Vancouver, pp. 2235–2238.
- Toledo, R., Ecofisiología y manejo del cultivo de soja. Available at: [http://campus.fca.uncu.edu.ar/pluginfile.php/15826/mod_resource/content/0/Ecofisiologia de soja Ing. Agr. Rubén E. Toledo Cereales y Oleaginosas%2C FCA-UNCORDOBA.pdf](http://campus.fca.uncu.edu.ar/pluginfile.php/15826/mod_resource/content/0/Ecofisiologia%20de%20soja%20Ing.%20Agr.%20Rub%C3%A9n%20E.%20Toledo%20Cereales%20y%20Oleaginosas%20FCA-UNCORDOBA.pdf).
- Toledo, R., 2014. Etapas de desarrollo de cultivo de Maiz. Available at: <http://es.slideshare.net/rubentoledo144/etapas-de-desarrollo-de-cultivo-de-maiz>.
- Tollenaar, M. & Daynard, T.B., 1978. Effect of defoliation on kernel development in maize. *Canadian Journal of Plant Science*, 58(1), pp.207–212.
- Tso, B. & Mather, P.M., 2009. *Classification methods for remotely sensed data*, Boca Raton: CRC press.

- Ullah, S. et al., 2013. Evaluation of three proposed indices for the retrieval of leaf water content from the mid-wave infrared (2 – 6 um) spectra. *Agricultural and Forest Meteorology*, 171–172, pp.65–71. Available at: <http://dx.doi.org/10.1016/j.agrformet.2012.11.014>.
- United States Geological Survey, Landsat Program. Available at: <https://landsat.usgs.gov/> [Accessed May 21, 2018].
- Vane, G., Billingsley, F.C. & Dunne, J.A., 1982. Observational parameters for remote sensing in the next decade. In *Advanced Multispectral Remote Sensing*. International Society for Optics and Photonics, pp. 52–65.
- Vapnik, V.N., 2000. *Statistics for Engineering and Information Science*, New York: Springer.
- Violini, S., 2016. *Uso de suelo agrícola en la zona central de Córdoba: análisis de datos espaciales multisensor para su estudio y gestión*. Universidad Nacional de Córdoba. Available at: <http://www.famaf.unc.edu.ar/vinculacion-2/divulgacion/publicaciones-de-la-famaf/tesis-de-maestrias/>.
- Vitousek, P.M., 1994. Beyond global warming: ecology and global change. *Ecology*, 75, pp.1861–1876.
- Waldner, F., Canto, G.S. & Defourny, P., 2015. Automated annual cropland mapping using knowledge-based temporal features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 110, pp.1–13.
- Wardlow, B.D. & Egbert, S.L., 2008. Large-area crop mapping using time-series MODIS 250 m NDVI data : An assessment for the U . S . Central Great Plains. *Remote Sensing of Environment*, 112, pp.1096–1116.
- Wardlow, B.D., Egbert, S.L. & Kastens, J.H., 2007. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U. S. Central Great Plains. *Remote Sensing of Environment*, 108, pp.290–310.
- Wibberley, J., 1996. A brief history of rotations, economic considerations and future directions. *Aspects of Applied Biology*, 47, pp.1–10.
- Willington, E., Nolasco, M. & Bocco, M., 2013. Clasificación supervisada de suelos de uso agrícola en la zona central de Córdoba (Argentina): comparación de distintos algoritmos sobre imágenes Landsat. In V Congreso Argentino de AgroInformática, ed. *V Congreso Argentino de AgroInformática*. Córdoba, pp. 207–216. Available at: <http://42jaiio.sadio.org.ar/proceedings/simposios/Trabajos/CAI/17.pdf>.
- Witten, I.H. & Frank, E., 2005. *Data Mining Practical Machine Learning Tools and Techniques*, San Francisco: Morgan Kaufmann.
- Xiong, J. et al., 2017. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 126, pp.225–244. Available at: <http://dx.doi.org/10.1016/j.isprsjprs.2017.01.019>.
- Yang, C., Everitt, J.H. & Murden, D., 2011. Evaluating high resolution SPOT 5 satellite imagery for crop identification. *Computers and Electronics in Agriculture*, 75, pp.347–354. Available at: <http://dx.doi.org/10.1016/j.compag.2010.12.012>.
- Zheng, B. et al., 2014. Remote sensing of crop residue and tillage practices : Present capabilities and future prospects. *Soil & Tillage Research*, 138, pp.26–34. Available at: <http://dx.doi.org/10.1016/j.still.2013.12.009>.
- Zheng, B. et al., 2015. Remote Sensing of Tillage Status. In *Land Resources Monitoring*,

Modeling, and Mapping with Remote Sensing. pp. 179–197.

Zheng, B., Campbell, J. & de Beurs, K., 2012. Remote sensing of crop residue cover using multi-temporal Landsat imagery. *Remote Sensing of Environment*, 117, pp.177–183. Available at: <http://dx.doi.org/10.1016/j.rse.2011.09.016>.

Zheng, Y., Zhang, M. & Wu, B., 2016. Using high spatial and temporal resolution data blended from SPOT-5 and MODIS to map biomass of summer maize. In *Agro-Geoinformatics*. pp. 1–5.

Zhong, L. et al., 2016. Automated mapping of soybean and corn using phenology. *ISPRS Journal of Photogrammetry and Remote Sensing*, 119, pp.151–164.

Zhong, L., 2012. *Efficient crop type mapping based on remote sensing in the Central Valley, California*. University of California, Berkeley.

Zhong, L., Gong, P. & Biging, G.S., 2014. Efficient corn and soybean mapping with temporal extendability : A multi-year experiment using Landsat imagery. *Remote Sensing of Environment*, 140, pp.1–13. Available at: <http://dx.doi.org/10.1016/j.rse.2013.08.023>.

Apéndice A

Matrices de confusión calculadas para cada modelo de clasificación evaluado.

Máxima Verosimilitud (ML_4)

Precisión Global = 94,8744%

Coeficiente Kappa = 0,9421

Datos de referencia a terreno (pixeles)														
Clases	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní	Urbano	Ruta asfaltada	Total	Prec. Usuario (%)
Maíz ext. temprano	0	0	0	0	0	0	0	0	0	0	0	0	0	--
Maíz temprano	0	114	0	0	0	0	0	0	0	0	0	0	114	100,00
Maíz intermedio	0	0	507	0	0	0	0	0	0	0	0	0	507	100,00
Maíz tardío	0	0	0	1065	0	0	0	0	0	0	0	0	1065	100,00
Maíz extra tardío	0	0	0	0	778	0	0	0	0	0	0	0	778	100,00
Soja temprana	0	0	0	0	0	871	0	0	0	0	0	0	871	100,00
Soja intermedia	0	0	0	0	0	0	639	7	0	0	0	0	646	98,92
Soja tardía	0	0	0	0	0	0	2	476	0	0	0	0	478	99,58
Sorgo	0	0	95	0	97	0	0	0	103	0	0	0	295	34,92
Maní	0	0	0	0	0	0	0	0	0	684	0	0	684	100,00
Urbano	121	471	401	124	20	358	102	588	284	14	626	52	3161	19,80
Ruta asfaltada	0	0	0	0	0	0	0	0	0	0	0	328	328	100,00
Total													8927	
	121	585	1003	1189	895	1229	743	1071	387	698	626	380		
Prec. Productor (%)	0,00	19,4	50,55	89,57	86,93	70,87	86,00	44,44	26,61	97,9	100,00	86,32		

Máxima Verosimilitud (ML_5)

Precisión Global = 94,8744%

Coeficiente Kappa = 0,9421

Datos de referencia a terreno (pixeles)												
Clases	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní	Total	Prec. Usuario (%)
Maíz ext. temprano	121	0	0	0	0	3	0	0	0	0	124	97,58
Maíz temprano	0	575	0	0	0	0	0	0	0	0	575	100,00
Maíz intermedio	0	4	755	0	1	0	0	0	0	0	760	99,34
Maíz tardío	0	1	0	1189	0	0	0	0	0	0	1190	99,92
Maíz extra tardío	0	0	0	0	779	0	0	0	0	0	779	100,00
Soja temprana	0	0	0	0	0	1226	0	0	0	0	1226	100,00
Soja intermedia	0	0	0	0	0	0	738	14	0	0	752	98,14
Soja tardía	0	0	0	0	0	0	4	1050	0	1	1055	99,62
Sorgo	0	5	248	0	115	0	1	7	387	2	765	50,59
Maní	0	0	0	0	0	0	0	0	0	695	695	100,00
Total	121	585	1003	1189	895	1229	743	1071	387	698	7921	
Prec. Productor (%)	100,00	98,29	75,27	100,00	87,04	99,76	99,33	98,04	100,00	99,57		

Máxima Verosimilitud (ML_6)

Precisión Global = 99,2101%

Coeficiente Kappa = 0,9908

Clases	Datos de referencia a terreno (pixeles)								Total	Prec. Usuario (%)
	Maíz extra temprano	Maíz temprano	Maíz intermedio	Maíz tardío	Maíz extra tardío	Soja temprana	Soja intermedia	Soja tardía		
Maíz ext. temprano	121	1	0	0	1	4	0	0	127	95,28
Maíz temprano	0	579	0	0	0	0	0	0	579	100,00
Maíz intermedio	0	4	1003	0	26	0	0	0	1033	97,10
Maíz tardío	0	1	0	1189	0	0	0	0	1190	99,92
Maíz extra tardío	0	0	0	0	867	0	0	0	867	100,00
Soja temprana	0	0	0	0	0	1225	0	0	1225	100,00
Soja intermedia	0	0	0	0	0	0	741	14	755	98,15
Soja tardía	0	0	0	0	1	0	2	1057	1060	99,72
Total	121	585	1003	1189	895	1229	743	1071	6836	
Prec. Productor (%)	100,00	98,97	100,00	100,00	96,87	99,67	99,73	98,69		

Máxima Verosimilitud (ML_7)

Precisión Global = 96,2990%

Coeficiente Kappa = 0,9245

Clases	Datos de referencia a terreno (porcentaje)			Total	Prec. Usuario(%)
	Maíz	Soja			
Maíz	3793	0		3793	100,00
Soja	253	2790		3043	91,69
Total	4046	2790		6836	
Prec. Productor (%)	93,75	100,00			

Random Forest (RF_4)

Precisión Global = 77,4076%

Coeficiente Kappa = 0,7506

Datos de referencia a terreno (pixeles)														
Clases	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní	Urbano	Ruta asfaltada	Total	Prec. Usuario (%)
Maíz ext. temprano	44	16	0	0	0	0	0	0	33	0	1	0	94	46,81
Maíz temprano	0	460	0	0	0	0	0	0	0	0	0	0	460	100,00
Maíz intermedio	0	109	279	0	0	0	0	0	48	0	0	0	436	63,99
Maíz tardío	0	0	60	1184	0	0	0	0	0	0	0	0	1244	95,18
Maíz extra tardío	0	0	352	0	868	0	0	0	0	0	0	0	1220	71,15
Soja temprana	0	0	0	0	0	1211	0	0	0	0	0	0	1211	100,00
Soja intermedia	0	0	0	0	0	2	742	48	154	0	0	0	946	78,44
Soja tardía	0	0	0	0	0	0	0	297	0	3	0	0	300	99,00
Sorgo	0	0	228	0	0	0	0	0	150	0	0	0	378	39,68
Maní	0	0	84	0	21	0	0	725	0	695	0	0	1525	45,57
Urbano	47	0	0	0	0	8	0	0	2	0	680	5	742	91,64
Ruta asfaltada	30	0	0	0	0	0	1	0	0	0	78	431	540	79,81
Total	121	585	1003	1184	889	1221	743	1070	387	698	759	436	9096	
Prec. Productor (%)	36,36	78,6	27,82	100,00	97,64	99,18	99,87	27,76	38,76	99,5	89,59	98,85		

Random Forest (RF_5)

Precisión Global = 76.7877%

Coeficiente Kappa = 0,7380

Clases	Datos de referencia a terreno (pixeles)										Total	Prec. Usuario (%)
	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní		
Maíz ext. temprano	93	178	0	0	0	0	9	0	89	0	369	25,20
Maíz temprano	0	336	0	0	0	0	0	0	0	0	336	100,00
Maíz intermedio	0	71	398	0	0	0	186	0	66	0	721	55,20
Maíz tardío	0	0	14	1184	0	0	0	0	0	0	1198	98,83
Maíz extra tardío	0	0	44	0	849	0	0	0	0	0	893	95,07
Soja temprana	28	0	0	0	0	1221	6	0	0	0	1255	97,29
Soja intermedia	0	0	0	0	0	0	410	0	96	0	506	81,03
Soja tardía	0	0	0	0	0	0	99	744	0	2	845	88,05
Sorgo	0	0	214	0	0	0	33	0	136	0	383	35,51
Maní	0	0	333	0	40	0	0	326	0	696	1395	49,89
Total	121	585	1003	1184	889	1221	743	1070	387	698	7901	
Prec. Productor (%)	76,86	57,44	39,68	100,00	95,50	100,00	55,18	69,53	35,14	99,71		

Random Forest (RF_6)

Precisión Global = 74,9266%

Coeficiente Kappa = 0,707964

Clases	Datos de referencia a terreno (pixeles)								Total	Prec. Usuario (%)
	Maíz extra temprano	Maíz temprano	Maíz intermedio	Maíz tardío	Maíz extra tardío	Soja temprana	Soja intermedia	Soja tardía		
Maíz ext. temprano	64	214	0	0	0	83	0	0	361	17,73
Maíz temprano	0	300	0	0	0	0	0	0	300	100,00
Maíz intermedio	57	71	225	0	0	0	190	0	543	41,44
Maíz tardío	0	0	127	1184	0	0	0	0	1311	90,31
Maíz extra tardío	0	0	638	0	889	0	0	281	1808	49,17
Soja temprana	0	0	0	0	0	1138	0	0	1138	100,00
Soja intermedia	0	0	0	0	0	0	553	35	588	94,05
Soja tardía	0	0	13	0	0	0	0	754	767	98,31
Total	121	585	1003	1184	889	1221	743	1070	6816	
Prec. Productor (%)	52,89	5,28	22,43	100,00	100,00	93,20	74,43	70,47		

Random Forest (RF_7)

Precisión Global = 94.3662%

Coeficiente Kappa = 0,884816

Clases	Datos de referencia a terreno (porcentaje)			Total	Prec. Usuario(%)
	Maíz	Soja			
Maíz	3741	343		4084	91,60
Soja	41	2691		2732	98,50
Total	3782	3034		6816	
Prec. Productor (%)	99,92	89,69			

Support Vector Machine (svm_4)

Precisión Global = 86,4445%

Coeficiente Kappa = 0,8496

Datos de referencia a terreno (pixeles)														
Clases	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní	Urbano	Ruta asfaltada	Total	Prec. Usuario (%)
Maíz ext. temprano	84	131	0	0	0	0	0	0	0	0	0	0	215	39,07
Maíz temprano	0	412	0	0	0	0	0	0	0	0	0	0	412	100,00
Maíz intermedio	0	42	712	0	0	0	0	0	120	0	1	0	875	81,37
Maíz tardío	0	0	144	1184	0	0	0	0	0	0	0	0	1328	89,16
Maíz extra tardío	0	0	128	0	883	0	0	0	0	0	0	0	1011	87,34
Soja temprana	8	0	0	0	0	1220	0	0	0	0	0	0	1228	99,35
Soja intermedia	0	0	0	0	0	0	741	20	197	0	0	0	958	77,35
Soja tardía	0	0	0	0	0	0	0	746	0	17	0	0	763	97,77
Sorgo	0	0	19	0	6	0	0	0	67	0	0	0	92	72,83
Maní	0	0	0	0	0	0	0	246	0	675	0	0	921	73,29
Urbano	9	0	0	0	0	1	0	58	3	6	703	0	780	90,13
Ruta asfaltada	20	0	0	0	0	0	2	0	0	0	55	436	513	84,99
Total	121	585	1003	1184	889	1221	743	1070	387	698	759	436	9096	
Prec. Productor (%)	69,42	70,4	70,99	100,00	99,33	99,92	99,73	69,72	17,31	96,7	92,62	100,00		

Support Vector Machine (svm_5)

Precisión Global = 82.8259%

Coeficiente Kappa = 0,805751

Datos de referencia a terreno (pixeles)												
Clases	Maíz ext. tem.	Maíz tem.	Maíz inter.	Maíz tardío	Maíz ext. tar.	Soja tem.	Soja inter.	Soja tardía	Sorgo	Maní	Total	Prec. Usuario (%)
Maíz ext. temprano	119	137	0	0	0	0	0	0	0	0	256	46,48
Maíz temprano	0	366	0	0	0	0	0	0	0	0	366	100,00
Maíz intermedio	0	82	652	0	0	0	0	0	57	0	791	82,43
Maíz tardío	0	0	78	1184	0	0	0	0	0	0	1262	93,82
Maíz extra tardío	0	0	219	0	883	0	0	0	0	0	1102	80,13
Soja temprana	2	0	0	0	0	1219	0	0	0	0	1221	99,84
Soja intermedia	0	0	0	0	0	0	743	263	184	2	1192	62,33
Soja tardía	0	0	0	0	0	0	0	552	0	16	568	97,18
Sorgo	0	0	54	0	6	0	0	0	146	0	206	70,87
Maní	0	0	0	0	0	2	0	255	0	680	937	72,57
Total	121	585	1003	1184	889	1221	743	1070	387	698	7901	
Prec. Productor (%)	98,35	62,56	65,00	100,00	99,33	99,84	100,00	51,59	37,73	97,42		

Support Vector Machine (svm_6)

Precisión Global = 92,8843%

Coeficiente Kappa = 0,916906

Clases	Datos de referencia a terreno (pixeles)								Total	Prec. Usuario (%)
	Maíz extra temprano	Maíz temprano	Maíz intermedio	Maíz tardío	Maíz extra tardío	Soja temprana	Soja intermedia	Soja tardía		
Maíz ext. temprano	121	150	0	0	0	0	0	0	271	44,65
Maíz temprano	0	401	0	0	0	0	0	0	401	100,00
Maíz intermedio	0	34	713	0	1	0	0	0	748	95,32
Maíz tardío	0	0	78	1184	0	0	0	0	1262	93,82
Maíz extra tardío	0	0	212	0	888	0	0	0	1100	80,73
Soja temprana	0	0	0	0	0	1221	0	0	1221	100,00
Soja intermedia	0	0	0	0	0	0	743	10	753	98,67
Soja tardía	0	0	0	0	0	0	0	1060	1060	100,00
Total	121	585	1003	1184	889	1221	743	1070	6816	
Prec. Productor (%)	100,0	68,55	71,09	100,00	99,89	100,00	100,00	99,07		

Support Vector Machine (svm_7)

Precisión Global = 95.8480%

Coeficiente Kappa = 0,916716

Clases	Datos de referencia a terreno (porcentaje)			Total	Prec. Usuario(%)
	Maíz	Soja			
Maíz	3499	283		3782	92,52
Soja	0	3034		3034	100,00
Total	3499	3317		6816	
Prec. Productor (%)	100,00	91,47			

Apéndice B

Verificación de la normalidad de los datos. Shapiro test:

```
> shapiro.test(rstandard(fit))  
  
      Shapiro-Wilk normality test  
  
data:  rstandard(fit)  
W = 0.899, p-value = 0.1797
```

El p-valor es mayor que el nivel de significancia (0.05), la hipótesis nula no es rechazada. Se asume una distribución del tipo normal para los datos.

Apéndice C

Análisis de la varianza.

31 agosto, 2013. HH band.

Entre clases

```
> summary(fit3)  
              Df Sum Sq Mean Sq F value    Pr(>F)  
d$clase      4  64.04  16.010    60.3 5.18e-06 ***  
Residuals    8   2.12   0.266  
---  
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
> TukeyHSD(fit3)  
  Tukey multiple comparisons of means  
  95% family-wise confidence level  
  
Fit: aov(formula = d$x ~ d$clase)  
  
$`d$clase`  
              diff          lwr          upr          p adj  
Sorghum-Corn      -4.756901 -6.8124800 -2.7013229 0.0003027  
Soybean-Corn      -3.023794 -4.3238562 -1.7237322 0.0002920  
Soybean-Corn-Corn -1.058897 -2.5124108  0.3946162 0.1789836  
Tilled soil-Corn  4.377037  2.3214585  6.4326156 0.0005437  
Soybean-Sorghum   1.733107 -0.2169858  3.6832002 0.0845443  
Soybean-Corn-Sorghum 3.698004  1.6424256  5.7535827 0.0017105  
Tilled soil-Sorghum 9.133939  6.6163792 11.6514978 0.0000109  
Soybean-Corn-Soybean 1.964897  0.6648349  3.2649590 0.0052147  
Tilled soil-Soybean 7.400831  5.4507383  9.3509243 0.0000078  
Tilled soil-Soybean-Corn 5.435934  3.3803558  7.4915129 0.0001157
```

Entre y dentro de las clases

ANAVA test:

```
> fit<-aov(db~c)  
> summary(fit)  
              Df Sum Sq Mean Sq F value    Pr(>F)  
c             11  24959  2269.0    435.3 <2e-16 ***  
Residuals    4898  25528     5.2
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Tukey test:

```
> TukeyHSD(fit)
  Tukey multiple comparisons of means
    95% family-wise confidence level
```

Fit: aov(formula = db ~ c)

Lotes	diff	lwr	upr	p adj
Lote_3-Lote_1	-0.328	-0.719	0.064	0.215
Lote_6-Lote_1	0.318	-0.200	0.836	0.712
Lote_9-Lote_1	-0.187	-0.685	0.312	0.991
Lote_10-Lote_1	-0.801	-1.374	-0.227	0.000
Lote_5-Lote_1	0.888	0.411	1.365	0.000
Lote_7-Lote_1	2.031	1.578	2.484	0.000
Lote_8-Lote_1	2.377	1.788	2.966	0.000
Lote_2b-Lote_1	2.438	1.873	3.003	0.000
Lote_3b-Lote_1	3.045	2.598	3.493	0.000
Lote_4-Lote_1	2.989	2.314	3.664	0.000
Lote_20-Lote_1	-1.933	-2.248	-1.617	0.000
Lote_7b-Lote_1	7.201	6.793	7.610	0.000
Lote_6-Lote_3	0.645	0.064	1.227	0.015
Lote_9-Lote_3	0.141	-0.424	0.705	1.000
Lote_10-Lote_3	-0.473	-1.104	0.158	0.386
Lote_5-Lote_3	1.216	0.671	1.762	0.000
Lote_7-Lote_3	2.359	1.834	2.883	0.000
Lote_8-Lote_3	2.705	2.059	3.351	0.000
Lote_2b-Lote_3	2.766	2.142	3.390	0.000
Lote_3b-Lote_3	3.373	2.854	3.893	0.000
Lote_4-Lote_3	3.317	2.592	4.042	0.000
Lote_20-Lote_3	-1.605	-2.017	-1.193	0.000
Lote_7b-Lote_3	7.529	7.042	8.016	0.000
Lote_9-Lote_6	-0.505	-1.163	0.154	0.348
Lote_10-Lote_6	-1.118	-1.835	-0.402	0.000
Lote_5-Lote_6	0.571	-0.072	1.213	0.143
Lote_7-Lote_6	1.713	1.088	2.338	0.000
Lote_8-Lote_6	2.059	1.329	2.789	0.000
Lote_2b-Lote_6	2.121	1.410	2.831	0.000
Lote_3b-Lote_6	2.728	2.107	3.348	0.000
Lote_4-Lote_6	2.671	1.871	3.472	0.000
Lote_20-Lote_6	-2.250	-2.784	-1.717	0.000
Lote_7b-Lote_6	6.884	6.290	7.477	0.000
Lote_10-Lote_9	-0.614	-1.316	0.089	0.161
Lote_5-Lote_9	1.075	0.449	1.702	0.000
Lote_7-Lote_9	2.218	1.609	2.826	0.000
Lote_8-Lote_9	2.564	1.848	3.280	0.000
Lote_2b-Lote_9	2.625	1.929	3.321	0.000
Lote_3b-Lote_9	3.232	2.628	3.837	0.000
Lote_4-Lote_9	3.176	2.388	3.964	0.000
Lote_20-Lote_9	-1.746	-2.260	-1.231	0.000
Lote_7b-Lote_9	7.388	6.812	7.965	0.000

Lote_5-Lote_10	1.689	1.001	2.377	0.000
Lote_7-Lote_10	2.832	2.160	3.503	0.000
Lote_8-Lote_10	3.178	2.408	3.947	0.000
Lote_2b-Lote_10	3.239	2.488	3.990	0.000
Lote_3b-Lote_10	3.846	3.179	4.513	0.000
Lote_4-Lote_10	3.790	2.953	4.627	0.000
Lote_20-Lote_10	-1.132	-1.719	-0.545	0.000
Lote_7b-Lote_10	8.002	7.360	8.644	0.000
Lote_7-Lote_5	1.143	0.551	1.734	0.000
Lote_8-Lote_5	1.489	0.788	2.190	0.000
Lote_2b-Lote_5	1.550	0.869	2.231	0.000
Lote_3b-Lote_5	2.157	1.570	2.744	0.000
Lote_4-Lote_5	2.101	1.326	2.875	0.000
Lote_20-Lote_5	-2.821	-3.315	-2.327	0.000
Lote_7b-Lote_5	6.313	5.755	6.871	0.000
Lote_8-Lote_7	0.346	-0.339	1.031	0.905
Lote_2b-Lote_7	0.407	-0.257	1.072	0.711
Lote_3b-Lote_7	1.015	0.447	1.582	0.000
Lote_4-Lote_7	0.958	0.199	1.718	0.002
Lote_20-Lote_7	-3.963	-4.434	-3.493	0.000
Lote_7b-Lote_7	5.170	4.633	5.708	0.000
Lote_2b-Lote_8	0.061	-0.702	0.825	1.000
Lote_3b-Lote_8	0.668	-0.013	1.350	0.060
Lote_4-Lote_8	0.612	-0.236	1.460	0.450
Lote_20-Lote_8	-4.310	-4.912	-3.707	0.000
Lote_7b-Lote_8	4.824	4.168	5.481	0.000
Lote_3b-Lote_2b	0.607	-0.053	1.267	0.109
Lote_4-Lote_2b	0.551	-0.281	1.382	0.595
Lote_20-Lote_2b	-4.371	-4.950	-3.792	0.000
Lote_7b-Lote_2b	4.763	4.128	5.398	0.000
Lote_4-Lote_3b	-0.056	-0.813	0.700	1.000
Lote_20-Lote_3b	-4.978	-5.443	-4.513	0.000
Lote_7b-Lote_3b	4.156	3.623	4.689	0.000
Lote_20-Lote_4	-4.922	-5.608	-4.235	0.000
Lote_7b-Lote_4	4.212	3.478	4.946	0.000
Lote_7b-Lote_20	9.134	8.706	9.562	0.000

31 agosto, 2013. VV band.

Entre clases

```
> summary(fit3)
```

```
      Df Sum Sq Mean Sq F value    Pr(>F)
d$class  4  75.04  18.759   33.09 5.04e-05 ***
Residuals  8   4.54   0.567
```

```
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
> TukeyHSD(fit3)
```

```
Tukey multiple comparisons of means
 95% family-wise confidence level
```

```
Fit: aov(formula = d$x ~ d$class)
```

```
$`d$class`
```

	diff	lwr	upr	p adj
Sorghum-Corn	-4.667081	-7.67089333	-1.663269	0.0043936
Soybean-Corn	-3.526549	-5.42632658	-1.626771	0.0013885
Soybean-Corn-Corn	-1.570328	-3.69434414	0.553688	0.1703071
Tilled soil-Corn	4.690317	1.68650511	7.694130	0.0042593
Soybean-Sorghum	1.140532	-1.70913446	3.990199	0.6537017
Soybean-Corn-Sorghum	3.096753	0.09294059	6.100565	0.0432479
Tilled soil-Sorghum	9.357398	5.67849468	13.036302	0.0001535
Soybean-Corn-Soybean	1.956221	0.05644306	3.855999	0.0434976
Tilled soil-Soybean	8.216866	5.36719970	11.066533	0.0000612
Tilled soil-Soybean-Corn	6.260646	3.25683317	9.264458	0.0006309

Entre y dentro de las clases

ANAVA test:

```
> fit2<-aov(expanded2$dB~expanded2$class)
> summary(fit2)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
expanded2\$class	11	30566	2778.7	513.3	<2e-16 ***
Residuals	4898	26516	5.4		

Signif. Codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Tukey test:

```
> TukeyHSD(fit2)
Tukey multiple comparisons of means
95% family-wise confidence level

Fit: aov(formula = expanded2$dB ~ expanded2$class)
```

Lotes	diff	lwr	upr	p adj
Lote_3-Lote_1	-0.695	-1.095	-0.294	0.000
Lote_6-Lote_1	0.521	-0.010	1.052	0.060
Lote_9-Lote_1	-1.189	-1.700	-0.679	0.000
Lote_10-Lote_1	-0.646	-1.233	-0.059	0.017
Lote_5-Lote_1	1.718	1.230	2.207	0.000
Lote_7-Lote_1	0.650	0.186	1.114	0.000
Lote_8-Lote_1	2.296	1.692	2.899	0.000
Lote_2b-Lote_1	3.145	2.567	3.724	0.000
Lote_3b-Lote_1	2.289	1.831	2.748	0.000
Lote_4-Lote_1	3.940	3.249	4.631	0.000
Lote_20-Lote_1	-1.542	-1.865	-1.219	0.000
Lote_7b-Lote_1	7.815	7.397	8.234	0.000
Lote_6-Lote_3	1.216	0.620	1.811	0.000
Lote_9-Lote_3	-0.494	-1.072	0.083	0.186
Lote_10-Lote_3	0.049	-0.597	0.695	1.000
Lote_5-Lote_3	2.413	1.855	2.971	0.000
Lote_7-Lote_3	1.344	0.808	1.881	0.000
Lote_8-Lote_3	2.990	2.329	3.652	0.000
Lote_2b-Lote_3	3.840	3.201	4.479	0.000

Lote_3b-Lote_3	2.984	2.452	3.516	0.000
Lote_4-Lote_3	4.635	3.893	5.377	0.000
Lote_20-Lote_3	-0.848	-1.269	-0.426	0.000
Lote_7b-Lote_3	8.510	8.012	9.008	0.000
Lote_9-Lote_6	-1.710	-2.384	-1.036	0.000
Lote_10-Lote_6	-1.167	-1.900	-0.433	0.000
Lote_5-Lote_6	1.197	0.539	1.855	0.000
Lote_7-Lote_6	0.129	-0.511	0.769	1.000
Lote_8-Lote_6	1.775	1.028	2.522	0.000
Lote_2b-Lote_6	2.624	1.897	3.352	0.000
Lote_3b-Lote_6	1.768	1.132	2.404	0.000
Lote_4-Lote_6	3.419	2.600	4.239	0.000
Lote_20-Lote_6	-2.063	-2.610	-1.517	0.000
Lote_7b-Lote_6	7.294	6.686	7.902	0.000
Lote_10-Lote_9	0.544	-0.176	1.263	0.372
Lote_5-Lote_9	2.907	2.266	3.549	0.000
Lote_7-Lote_9	1.839	1.216	2.462	0.000
Lote_8-Lote_9	3.485	2.752	4.218	0.000
Lote_2b-Lote_9	4.334	3.622	5.047	0.000
Lote_3b-Lote_9	3.478	2.859	4.098	0.000
Lote_4-Lote_9	5.129	4.322	5.936	0.000
Lote_20-Lote_9	-0.353	-0.880	0.174	0.575
Lote_7b-Lote_9	9.004	8.414	9.594	0.000
Lote_5-Lote_10	2.364	1.660	3.068	0.000
Lote_7-Lote_10	1.295	0.608	1.982	0.000
Lote_8-Lote_10	2.941	2.153	3.729	0.000
Lote_2b-Lote_10	3.791	3.021	4.560	0.000
Lote_3b-Lote_10	2.935	2.251	3.618	0.000
Lote_4-Lote_10	4.586	3.729	5.443	0.000
Lote_20-Lote_10	-0.897	-1.498	-0.295	0.000
Lote_7b-Lote_10	8.461	7.803	9.118	0.000
Lote_7-Lote_5	-1.069	-1.674	-0.463	0.000
Lote_8-Lote_5	0.577	-0.141	1.295	0.272
Lote_2b-Lote_5	1.427	0.730	2.124	0.000
Lote_3b-Lote_5	0.571	-0.030	1.172	0.082
Lote_4-Lote_5	2.222	1.429	3.015	0.000
Lote_20-Lote_5	-3.260	-3.766	-2.755	0.000
Lote_7b-Lote_5	6.097	5.526	6.668	0.000
Lote_8-Lote_7	1.646	0.945	2.347	0.000
Lote_2b-Lote_7	2.496	1.815	3.176	0.000
Lote_3b-Lote_7	1.640	1.058	2.221	0.000
Lote_4-Lote_7	3.290	2.512	4.068	0.000
Lote_20-Lote_7	-2.192	-2.674	-1.710	0.000
Lote_7b-Lote_7	7.166	6.615	7.716	0.000
Lote_2b-Lote_8	0.850	0.068	1.632	0.019
Lote_3b-Lote_8	-0.006	-0.704	0.691	1.000
Lote_4-Lote_8	1.644	0.776	2.513	0.000
Lote_20-Lote_8	-3.838	-4.455	-3.221	0.000
Lote_7b-Lote_8	5.519	4.847	6.192	0.000
Lote_3b-Lote_2b	-0.856	-1.533	-0.179	0.002
Lote_4-Lote_2b	0.795	-0.057	1.646	0.096
Lote_20-Lote_2b	-4.688	-5.281	-4.094	0.000
Lote_7b-Lote_2b	4.670	4.020	5.320	0.000
Lote_4-Lote_3b	1.651	0.876	2.426	0.000

Lote_20-Lote_3b	-3.831	-4.308	-3.355	0.000
Lote_7b-Lote_3b	5.526	4.980	6.072	0.000
Lote_20-Lote_4	-5.482	-6.185	-4.779	0.000
Lote_7b-Lote_4	3.875	3.123	4.627	0.000
Lote_7b-Lote_20	9.357	8.919	9.796	0.000

Apéndice D

Intervalos de confianza radiométrica en función del Número Equivalente de Looks (ENL)

dB	dB	dB	dB	dB	dB	dB	dB	dB	dB	dB	dB	dB	Error-dB
0.5	1.0	1.5	2.0	2.5	3.0	3.5	4.0	4.5	5.0	5.5	6.0		
Confidence level, %												equivalent NL:	
8	16	24	32	40	47	53	59	64	68	72	75	1	
12	24	35	46	56	64	71	77	81	85	88	90	2	
15	30	43	55	66	74	81	86	89	92	94	95	3	
17	34	49	62	73	81	87	91	93	95	97	98	4	
19	38	54	68	78	86	90	94	96	97	98	98	5	
26	50	69	82	90	95	97	98	99	99	99	99	9	
28	53	71	84	92	96	98	99	99	99	99	99	10	
34	62	81	92	97	99	99	99	99	99	99	99	15	
39	69	87	96	99	99	99	99	99	99	99	99	20	
59	89	98	99	99	99	99	99	99	99	99	99	50	
75	97	99	99	99	99	99	99	99	99	99	99	100	
84	99	99	99	99	99	99	99	99	99	99	99	150	
89	99	99	99	99	99	99	99	99	99	99	99	200	
93	99	99	99	99	99	99	99	99	99	99	99	250	

Figura 59. Intervalos de confianza de acuerdo al NEL y la diferencia en dB. Extraído de Laur et al. (2004)