Caracterización de los usos y coberturas del suelo mediante teledetección en el partido de Azul, Buenos Aires.

Trabajo final presentado para optar al título de
Especialista en Teledetección y Sistemas de Información Geográfica aplicados al estudio de los recursos naturales y la producción agropecuaria

Emiliano José Arduini
Ingeniero Agrónomo - Universidad de Buenos Aires - 2010

Lugar de trabajo: Dirección Técnica de Forestoindustria – Instituto Nacional de Tecnología Industrial

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

TUTOR

Pablo Baldassini
Licenciado en Ciencias Ambientales (Universidad de Buenos Aires)
Doctor en Ciencias Agropecuarias (Universidad de Buenos Aires)

JURADO DE TRABAJO FINAL

Jurado
Germán Baldi
Licenciado en Ciencias Biológicas (Universidad de Buenos Aires)
Doctor en Ciencias Agropecuarias (Universidad de Buenos Aires)

Jurado
Mayra Milkovic
Licenciada en Ciencias Biológicas (Universidad de Buenos Aires)
Magister en Recursos Naturales (Universidad de Buenos Aires)

Fecha de defensa del Trabajo Final: 17 de noviembre de 2020

Agradecimientos

A mi tutor, Pablo Baldassini, quien me guio en todo momento y dedicó su tiempo, siempre que lo necesite para poder llevar a cabo el presente trabajo. A Mariano Oyarzabal por sus consejos y acompañamiento con toda predisposición. A Julieta Straschnoy por su ayuda y motivación para realizar y finalizar el trabajo.

Declaración

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

Índice General

Resumen 9
1. Introducción 10
2. Materiales y Métodos 12
2.1. Área de estudio 12
2.2. Procesamiento de imágenes satelitales y verdad terrestre 14
2.3. Proceso de clasificación 15
2.4. Evaluación de la clasificación 17
2.5. Análisis de los cambios temporales en el uso y cobertura del suelo 18
3. Resultados y Discusión 19
3.1. Campaña 2013-2014 19
3.2. Campaña 2014-2015 22
3.3. Campaña 2015-2016 26
3.4. Comparación entre campañas 29
3.5. Proporción de usos del suelo por campaña 32
4. Conclusión 35
5. Bibliografía 37

Índice de Tablas

Tabla 1. Superficie de las principales actividades agrícola ganaderas del partido de Azul (MAGyP, 2015) 14

Tabla 2. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo 20

Tabla 3. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo 20

Tabla 4. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo 21

Tabla 5. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo 21

Tabla 6. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo 23

Tabla 7. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo 23

Tabla 8. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo 24

Tabla 9. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo 24

Tabla 10. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo 26

Tabla 11. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo 27

Tabla 12. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo 27

Tabla 13. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo ..28

Tabla 14. Precisión general de todas las combinaciones de procedimientos y campañas ...30

Tabla 15. Precisión general, error de omisión y error de comisión de todas las combinaciones de procedimientos y campañas para dos grupos de clases 31

Tabla 16. Superficie e intervalo de confianza de tres grupos de clases, estimado con el método de Olofsson et al. (2014), para cada campaña bajo estudio 32

Tabla 17. Superficie e intervalo de confianza de cada clase, estimado con el método de Olofsson et al. (2014), para cada campaña bajo estudio 32

Tabla 18. Cantidad de píxeles y superficie de distintos grupos de clases que han mostrado o no cambios en la cobertura de suelo.....33

Tabla 19. Superficie de las transiciones ocurridas entre las clases de coberturas en el período analizado (2013-2016) 35

Índice de Figuras

Figura 1. Ubicación geográfica del partido de azul 13
Figura 2. Diagrama de flujo de los procesos realizados para la clasificación.....16
Figura 3. Ejemplo de matriz de confusión 18
Figura 4. Diagrama de flujo del procedimiento para la generación del mapa con las transiciones de la cobertura del suelo 19
Figura 5. Mapa de la cobertura de suelo del partido de Azul para la campaña 2013-2014 ..22
Figura 6. Mapa de la cobertura de suelo del partido de Azul para la campaña 2014-2015 ..25
Figura 7. Mapa de la cobertura de suelo del partido de Azul para la campaña 2015-2016 ..29
Figura 8. Mapa de cambios en la cobertura del suelo durante las campañas 2013-2014, 2014-2015 y 2015-2016 34

Resumen

Estimar la superficie agrícola es fundamental para mejorar la logística productiva y generar políticas públicas. En Argentina, la estimación de la superficie agrícola proviene principalmente de las Estimaciones Agrícolas del Ministerio de Agricultura, Ganadería y Pesca (MAGyP) y del Censo Nacional Agropecuario (CNA) del Instituto Nacional de Estadísticas y Censos (INDEC). Como alternativa, se utilizan imágenes satelitales. Tiene la ventaja de disponer de información no solo espacial sino también temporal de la superficie agrícola, y otros usos. En Argentina existen trabajos previos de clasificaciones de coberturas del suelo. Sin embargo, existen pocos ejemplos de mapas de cultivos a escala nacional y con continuidad a través de los años. El objetivo de este trabajo fue caracterizar los usos y coberturas del suelo del partido de Azul, provincia de Buenos Aires, durante el período 2013-2016. Se combinaron imágenes satelitales provistas por el satélite Landsat 8 con información de verdad terrestre relevada por el método de Segmentos Aleatorios (MAGyP) e información obtenida mediante fotointerpretación de imágenes de alta resolución con Google Earth. A su vez, se describieron los principales cambios de la cobertura terrestre. Se realizaron clasificaciones supervisadas utilizando el algoritmo Random Forest a través de la plataforma Google Earth Engine y se generaron mapas de cobertura del suelo. La utilización completa de la información terrestre redundó en una baja precisión general (56%). Sin embargo, al realizar una selección aleatoria balanceada de puntos en cada clase, la precisión general aumentó (84%). El área cubierta por cultivos fue superior a la cubierta por recursos forrajeros en las tres campañas estudiadas. El cultivo de soja fue la clase de cobertura más frecuente en las tres campañas, con el 40% de superficie en promedio. El 93,4% de la superficie presentó algún tipo de cambio en la cobertura del suelo a lo largo de las tres campañas. Se espera que la generación de clasificaciones de uso del suelo de manera periódica permita caracterizar a nivel de lote cuestiones importantes relacionadas con la sustentabilidad del manejo agrícola, como la rotación de cultivos y la intensidad de uso del suelo.

Palabras clave: Landsat, cobertura del suelo, clasificación supervisada, teledetección, imágenes satelitales, Google Earth Engine.

1. Introducción

Estimar la superficie agrícola en países donde su economía depende en gran medida de la producción primaria es fundamental para desarrollar mejores estrategias productivas y generar políticas públicas generales, sectoriales y regionales. Diversos actores como productores, exportadores, proveedores de insumos, entidades financieras, compañías de seguros, y organismos de gobierno necesitan la información para la planificación y la toma de decisiones de sus actividades. El desarrollo de bases de datos regionales y globales de tipos de cobertura del suelo es un requisito indispensable en la toma de decisiones a distintos niveles (Hansen *et al*., 2000; Mc Guire *et al*., 2001).

En Argentina, las estimaciones de la superficie agrícola provienen principalmente de las Estimaciones Agrícolas del Ministerio de Agricultura, Ganadería y Pesca (MAGyP) y del Censo Nacional Agropecuario (CNA) del Instituto Nacional de Estadísticas y Censos (INDEC). Las Estimaciones Agrícolas tienen una frecuencia semestral, mientras que el CNA se realiza cada 10 años aproximadamente. Históricamente, los procedimientos utilizados para la elaboración de información por parte del MAGyP se basaron en los denominados "métodos subjetivos" a partir de informantes calificados, los que fueron mejorados a partir de la incorporación de controles y validaciones con datos provenientes de otras fuentes comerciales y productivas (acopiadores, cooperativas, productores, distribuidores de agroquímicos y semillas, etc.) (MAGyP, s. f.). Sin embargo, la forma de generar dicha información incluye distintas fuentes de incertidumbre que podrían afectar las estimaciones, incluyendo las dificultades para referir a un área completa, las posibilidades de los informantes de integrar la información local, la ausencia de protocolos únicos y las diferencias asociadas a la heterogeneidad de formación, motivación y compromiso de los informantes en el espacio y el tiempo. El CNA, por su parte, es un relevamiento que se realiza sobre todas las explotaciones agropecuarias del país, con el propósito de obtener información sobre las características básicas de las actividades agrícolas, ganaderas, forestales y bioindustriales (INDEC, 2018). La principal limitante para la gran mayoría de los usuarios es la frecuencia con que se realiza. Es por ello que es necesario contar con información que esté disponible en tiempo y forma, y que posea consistencia y coherencia de los datos a efectos de lograr confiabilidad.

En los últimos años, la Dirección de Información Agropecuaria y Forestal del MAGyP ha desarrollado e implementado un nuevo método con mayor grado de objetividad, denominado Segmentos Aleatorios, para la estimación de la superficie sembrada de cultivos extensivos en las diferentes zonas agropecuarias del país (Della Valle y de Nuria Dufour, 2013). El mismo se basa en obtener una numerosa cantidad de unidades de muestreo de manera aleatoria en áreas relativamente pequeñas. Esta información de uso del suelo la suministra un observador en campo. En ella se identifican cada una de las diferentes coberturas agropecuarias que se presentan. Este método permite obtener estimaciones de los valores poblacionales que corresponden a la verdadera cantidad de hectáreas cultivadas. Si bien este método es una mejora respecto a los métodos

subjetivos anteriormente mencionados, sigue siendo una estimación en base a una pequeña muestra de la superficie y con una frecuencia temporal baja.

La utilización de imágenes satelitales para clasificar la cobertura del suelo es una de las prácticas más frecuentes del uso de la teledetección, ya que tiene la ventaja de disponer de información no solo espacial sino también temporal abarcando completamente el total de la superficie terrestre. La definición de clases de cobertura del suelo utilizando datos de sensores remotos, se basa en la diferencia de reflectancia detectada entre los distintos tipos de cobertura del suelo. Cada tipo de cobertura del suelo presenta una firma espectral distinta, es decir, cada cubierta de la superficie terrestre presenta un patrón propio de reflexión. Si bien la energía incidente que es reflejada en cada longitud de onda está influenciada casi exclusivamente por características propias de la superficie analizada, también tienen incidencia otros componentes del sistema de teledetección, como el canopeo, el sensor, la fuente de energía y la geometría de la medición y la atmósfera, entre otros (Beget y Di Bella, 2014).

Sin embargo, distintos tipos de cobertura de suelo pueden mostrar respuestas espectrales similares en un momento dado y son difíciles de diferenciar a partir de una sola imagen. Para una determinada fecha del año, dos clases de cobertura del suelo son difíciles de discriminar si tienen un índice de área foliar similar o se encuentran en la misma etapa fenológica. Por lo tanto, la aplicación de imágenes multitemporales, que proporcionan información adicional sobre la fenología de la vegetación, mejora la discriminación de los tipos de cobertura terrestre. Guerschman *et al.* (2003) demostraron que se deben utilizar al menos dos escenas Landsat de la misma estación de crecimiento para la identificación adecuada de los tipos de cobertura del suelo. Las fechas de estas escenas deberían abarcar el cambio entre los cultivos de invierno y verano. El uso de datos multitemporales permite aumentar la separabilidad espectral entre cultivos agrícolas (Murthy *et al*., 2003). Guerschman (2005) y Wardlow *et al.* (2007) utilizaron productos de imágenes MODIS para el relevamiento de los principales cultivos de la región pampeana de Argentina y del Valle Central de EE.UU., respectivamente. Para ello, utilizaron protocolos basados en análisis de series temporales de índices de vegetación (IV) registrados con frecuencia quincenales. Estas permiten estudiar el comportamiento estacional de la vegetación y discriminar clases de coberturas vegetales, identificando patrones de funcionamiento característicos o "firmas fenológicas", que corresponden a la dinámica de la interceptación de radiación por parte del canopeo.

Para llevar a cabo un proceso de clasificación en donde se desea obtener un mapa de clases definidas a priori, es necesario contar con información terrestre de referencia de cada una de esas categorías, denominadas "áreas de entrenamiento" (Paruelo, 2014). A su vez, se debe evaluar la capacidad predictiva de la clasificación de manera cuantitativa también con información terrestre de referencia. La evaluación basada en el contraste con observaciones de campo es esencial para establecer la incertidumbre de la estimación y establecer sobre bases objetivas su confiabilidad (Congalton, 1991).

En Argentina existen trabajos previos de clasificaciones de coberturas del suelo, y de sus cambios temporales. Volante *et al.* (2007a) evaluaron la eficiencia de dos metodologías distintas de clasificación de cultivos en la zona de Las Lajitas provincia de Salta. Bagnato *et al.* (2012) proponen una metodología repetible para la obtención de mapas de uso agrícola y estimación de superficie sembrada, a escala de lote. En Río Segundo y Santa María, Córdoba, Nolasco *et al.* (2014) realizaron una clasificación de cultivos utilizando imágenes Landsat multitemporales y obtuvieron una mayor precisión respecto de una clasificación realizada con datos una sola escena. También se realizaron distintos estudios para detectar cambios temporales de la cobertura del suelo. En el departamento de Burruyacu de la provincia de Tucumán, el análisis multitemporal de imágenes provenientes de distintos sensores permitió identificar, cuantificar y representar espacialmente distintas secuencias de cultivos estivales (Fandos *et al*., 2019). Díaz Gómez y Gasparri (2017) utilizando imágenes Landsat 5 de dos fechas distintas lograron cuantificar el cambio de uso y cobertura del suelo (principalmente la deforestación) en la zona ribereña en las cuencas subtropicales del Faldeo Oriental de las Sierras del Aconquija y Sierras del Sudoeste (FOAS) del Noroeste Argentino, durante el período 1986- 2010. Vázquez *et al.* (2016) analizaron el proceso de agriculturización en el partido de Azul entre 1995 y 2011 a partir de imágenes Landsat 5 de dos fechas distintas. Volante *et al*. (2007b), caracterizaron las rotaciones de cultivos en el Noroeste Argentino entre el 2000 y 2005 utilizando imágenes Landsat y SAC-C de diferentes fechas.

A escala nacional, el Instituto Nacional de Tecnología Agropecuaria (INTA) generó por primera vez un mapa de tipos de cultivo para el área agrícola extensiva de Argentina para las campañas 2018-2019 (INTA, 2019) y 2019-2020 (INTA, 2020) utilizando plataformas de almacenamiento y procesamiento de imágenes satelitales en la nube y nuevos algoritmos de clasificación supervisada. Sin embargo, con solo dos campañas disponibles, el análisis de transiciones o rotaciones en la cobertura del suelo que se puede realizar es acotado temporalmente.

El objetivo de este trabajo fue caracterizar los usos y coberturas del suelo del partido de Azul, provincia de Buenos Aires, en el período 2013-2016, a partir de información muestral relevada a campo por el método de Segmentos Aleatorios del MAGyP y de imágenes satelitales Landsat 8. A su vez, describir las principales transiciones de la cobertura terrestre en dicha área de estudio.

2. Materiales y Métodos

2.1. Área de estudio

El área de estudio se localizó en el partido de Azul, que está ubicado en el centro de la provincia de Buenos Aires. Los partidos limítrofes son: al norte, Las Flores y Tapalqué; al este, Rauch y Tandil; al oeste, Olavarría y; al sur, Benito Juárez. Se encuentra a una

latitud de 36°48' Sur, una longitud de 59°51' Oeste, posee una altitud media de 136 msnm y ocupa 6.615 km² de superficie (Figura 1).

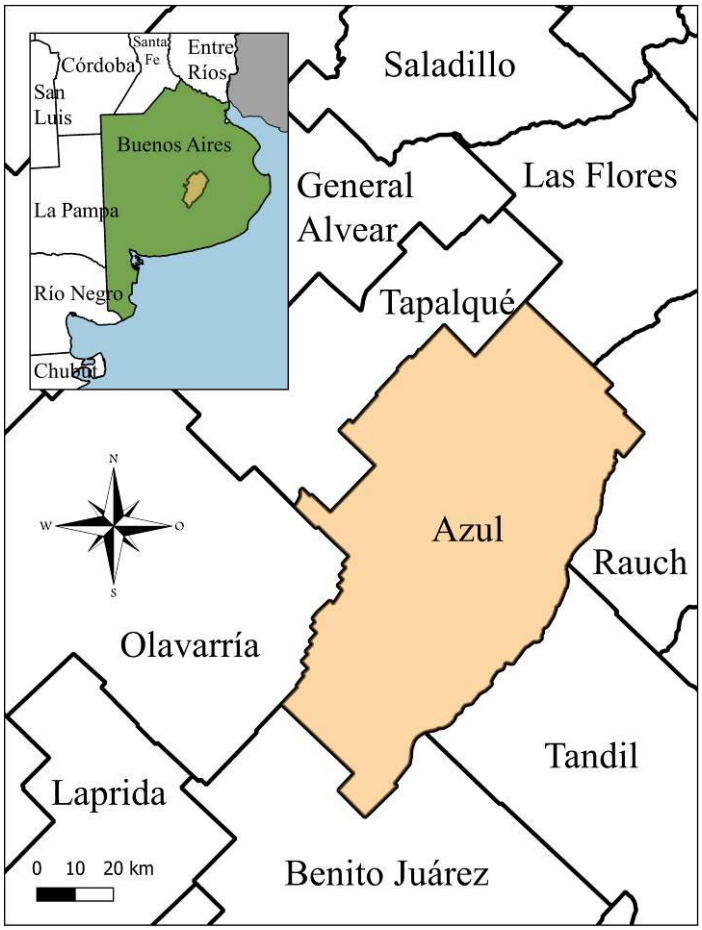

Figura 1. Ubicación geográfica del partido de azul.

Azul dispone de un 32% de su superficie con suelos aptos para cultivos y de un 54% con suelos bajo uso ganadero (MAGyP, 2015). El principal cultivo de invierno es el trigo, seguido por la cebada y la avena. El principal cultivo de verano es la soja, seguido por el maíz y el girasol (MAGyP, 2015). La mayor parte de la superficie de uso ganadero se dedica al pastoreo en pastizales naturales o seminaturales, seguido por pasturas permanentes (MAGyP, 2015) (Tabla 1).

	Superficie	
	(ha)	(%)
Uso agrícola	**202349**	**32,2**
Soja 1ra	72000	11,5
Soja 2da	20100	3,2
Maíz	40000	6,4
Girasol	13200	2,1
Sorgo	1700	0,3
Trigo	34500	5,5
Cebada cervecera	34000	5,4
Avena	6500	1,0
Alpiste	2500	0,4
Uso ganadero	**339365**	**54,0**
Campo natural	293310	46,7
Pasturas permanentes	25038	4,0
Otros	21016	3,3
Destino no especificado	**20978**	**3,3**
Desperdicio	**65804**	**10,5**
Total	**628465**	**100**

Tabla 1. Superficie de las principales actividades agrícola ganaderas del partido de Azul (MAGyP, 2015).

2.2. Procesamiento de imágenes satelitales y verdad terrestre

Para la adquisición y el procesamiento de las imágenes satelitales se utilizó la plataforma Google Earth Engine (GEE). GEE es una plataforma de procesamiento y análisis geoespacial de código abierto y gratuito que permite almacenamiento parcial o total en la nube. Contiene un catálogo con petabytes de imágenes de diferentes satélites permitiendo realizar análisis y visualización de datos a distintas escalas espaciales y temporales para todo el planeta. Se utilizaron imágenes del satélite Landsat 8 con datos de reflectancia superficial, ortorectificadas y con corrección atmosférica (producto Landsat 8 Surface Reflectance Tier 1). A su vez, se aplicó un filtro de calidad utilizando la banda *pixel qa* para filtrar pixeles que presenten nubes o sombras. Las bandas espectrales utilizadas fueron la 2 (azul), 3 (verde), 4 (rojo), 5 (infrarrojo cercano), 6 (infrarrojo de onda corta 1) y 7 (infrarrojo de onda corta 2). Se utilizaron todas las imágenes disponibles de los períodos del 1 de septiembre al 31 de mayo para las tres campañas identificadas en el período 2013-2016.

Como verdad de campo, se utilizó información brindada por el Método de Segmentos Aleatorios creado por el Ministerio de Agricultura ganadería y Pesca (Della Valle y de Nuria Dufour, 2013). Se utilizó la información de las campañas del 2013-2014, 2014-2015 y 2015-2016 correspondientes al partido de Azul. En dicho método, se define al segmento como unidad estadística de muestreo a la superficie en forma de polígono generalmente rectangular, generado a partir de una ruta o un camino identificable a ambos lados de la línea de recorrido, con una distancia entre el punto inicial y final del orden de los 4 kilómetros y un ancho de 500 metros de cada lado. La superficie total de cada segmento es aproximadamente 400 hectáreas. A su vez, los segmentos están

compuestos por un conjunto de lotes. El tamaño de la muestra es una estimación basada en el conocimiento de la superficie de las jurisdicciones, la cantidad y composición de los lotes que se observan en imágenes satelitales y la disponibilidad de información anterior de la zona.

Los segmentos elegidos son relevados a campo dos veces al año (para identificar cultivos de cosecha fina y gruesa) constituyendo una verdad terrestre. En ellos, se identifican las Unidades de Uso de Suelo (UUS) que son las diferentes coberturas agropecuarias presentes. A continuación se listan las UUS posibles a ser relevadas:

-Cultivos
  -Cereales: Alpiste, Arroz, Avena, Cebada, Centeno, Maíz de 1º, Maíz de 2º, Mijo, Sorgo Granífero de 1º, Sorgo Granífero de 2º y Trigo.
  -Oleaginosas: Algodón, Cártamo, Colza, Girasol de 1º, Girasol de 2º, Lino, Maní, Soja de 1º, Soja de 2º.
  -Legumbres: Arveja Seca, Garbanzo, Lenteja y Poroto.
-Otros cultivos
-Pasturas permanentes
-Campo natural
-Barbecho: convencional o químico
-Rastrojo: de cosecha fina o de cosecha gruesa
-Potrero

A su vez, se incorporó información obtenida a través de fotointerpretación de imágenes satelitales de alta resolución con la plataforma Google Earth, de áreas correspondientes a las clases de forestación, agua permanente, zona urbana y afloramiento rocoso. Estas coberturas no están identificadas en la información suministrada por el Método de Segmentos Aleatorios. Las mismas, se consideraron necesarias para la clasificación ya que, en caso de no incluirlas, el proceso de clasificación llevaría a la sobrestimación de la superficie de las coberturas de uso agrícola-ganaderas de interés. Finalmente, toda la información de datos terrestres se agrupó en 9 clases de cobertura del suelo: cultivo de invierno-soja de segunda (incluye trigo, avena, cebada y centeno), soja de primera, maíz, girasol, recursos forrajeros (incluye campo natural y pasturas), forestación, agua permanente, áreas urbanas y afloramientos rocosos.

2.3. Proceso de clasificación

Con las imágenes satelitales se realizaron dos procedimientos diferentes. En primer lugar, se dividió el período de la campaña (1 de septiembre al 31 de mayo) en tres subperíodos: primavera (1 de septiembre al 31 de noviembre), verano (1 de diciembre al 28 de febrero) y otoño (1 marzo al 31 de mayo). Con los datos de reflectancia superficial se calculó la mediana de cada subperíodo para cada banda de la imagen. Finalmente, se armó un apilamiento de 18 bandas (6 bandas por subperíodos) que contenían la mediana calculada para cada banda y período considerado. En segundo

lugar, se calculó la mediana y el desvío estándar de los datos de reflectancia superficial para todo el período de la campaña (1 de septiembre al 31 de mayo). Con estos datos se armó un apilamiento de 12 bandas (6 bandas con los datos de mediana y 6 bandas con los datos de desvío estándar) (Figura 2).

Con los datos de verdad de campo se realizaron dos procedimientos diferentes. Por un lado, se realizó una selección aleatoria de polígonos dentro de cada clase. El 70% se seleccionó para el entrenamiento del algoritmo de clasificación y el 30% restante para la evaluación. Por otro lado, se realizó un procedimiento de selección aleatoria de puntos dentro de cada clase para balancear la cantidad de información a utilizar en el proceso de entrenamiento. De esta manera, cada clase de cobertura del suelo presentaba la misma cantidad de puntos. Del mismo modo que el procedimiento anterior, el 70% de puntos se utilizó para el entrenamiento y el 30% restante para la evaluación (Figura 2).

Combinando todos los procedimientos anteriormente detallados se realizaron clasificaciones supervisadas para cada una de las tres campañas bajo estudio y se obtuvieron cuatro mapas de coberturas de suelo por campaña. A cada una de las clasificaciones se le aplicó un filtro post-clasificación de mayoría considerando una ventana espacial de 3x3 pixeles con el fin de eliminar el efecto "sal y pimienta" (Chuvieco, 1990). En la figura 2, se muestra el diagrama de flujo de los procesos realizados.

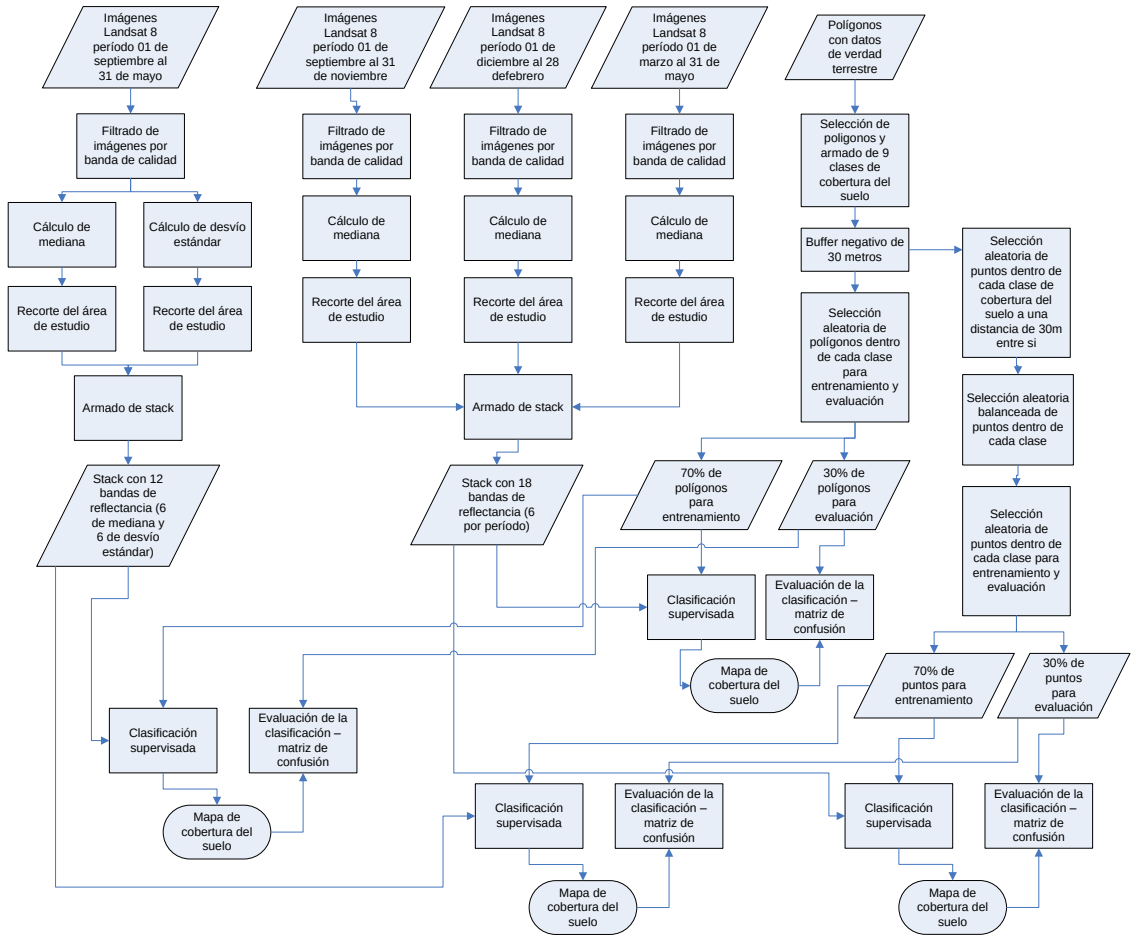

Figura 2. Diagrama de flujo de los procesos realizados para la clasificación.

Para clasificar se utilizó el algoritmo Random Forest que fue propuesto por Breiman (2001). Se trata de un algoritmo no paramétrico de aprendizaje automático que genera y combina un conjunto de árboles de decisión, donde cada uno se genera usando un subconjunto de elementos de entrenamiento diferente en cada iteración, y los nodos se dividen utilizando la mejor de las variables de una muestra aleatoria de estas. La clase de salida se obtiene como la selección de la mayoría de las salidas de un gran número de árboles individuales (Breiman, 2001). Random Forest es uno de los algoritmos de clasificación de imágenes más usados en teledetección, y se obtienen mejores resultados que con otros algoritmos (Pal, 2005; Gislason *et al*., 2006).

2.4. Evaluación de la clasificación

Para la evaluación de la clasificación, se utilizaron datos independientes de los datos utilizados en el entrenamiento del algoritmo de clasificación. Las clasificaciones que se realizaron utilizando polígonos se evaluaron utilizando los píxeles incluidos en el 30% de los polígonos reservados para tal fin. Las clasificaciones que se realizaron utilizando puntos se evaluaron utilizando los píxeles coincidentes con el 30% de los puntos seleccionados para la evaluación.

La precisión de las clasificaciones fue evaluada mediante un análisis de matrices de confusión. La matriz de confusión consta de una tabla de doble entrada, que compara los valores observados o verdad de terreno con los resultados de la clasificación. Los datos de las columnas corresponden a los valores observados y los de las filas a los predichos por la clasificación. Un píxel correctamente clasificado estará ubicado en la diagonal de esta matriz, mientras que en cualquiera de las otras ubicaciones dentro de la matriz se tratará de errores de asignación (Paruelo, 2014). Este es el método más comúnmente utilizado para validar este tipo de clasificaciones (Foody, 2002). A su vez, a partir de la matriz de confusión, se calculó la precisión general, el error de comisión y el error de omisión (Figura 3). La precisión general indica la relación entre los pixeles correctamente clasificados y el total de pixeles. El error de comisión indica la sobrestimación de los píxeles que realmente deberían pertenecer a una clase, mientras que el error de omisión indica la subestimación de los píxeles que realmente deberían pertenecer a una clase. A su vez, se estimó la superficie e intervalo de confianza de cada clase con el método de Olofsson *et al*. (2014) para las tres campañas bajo estudio.

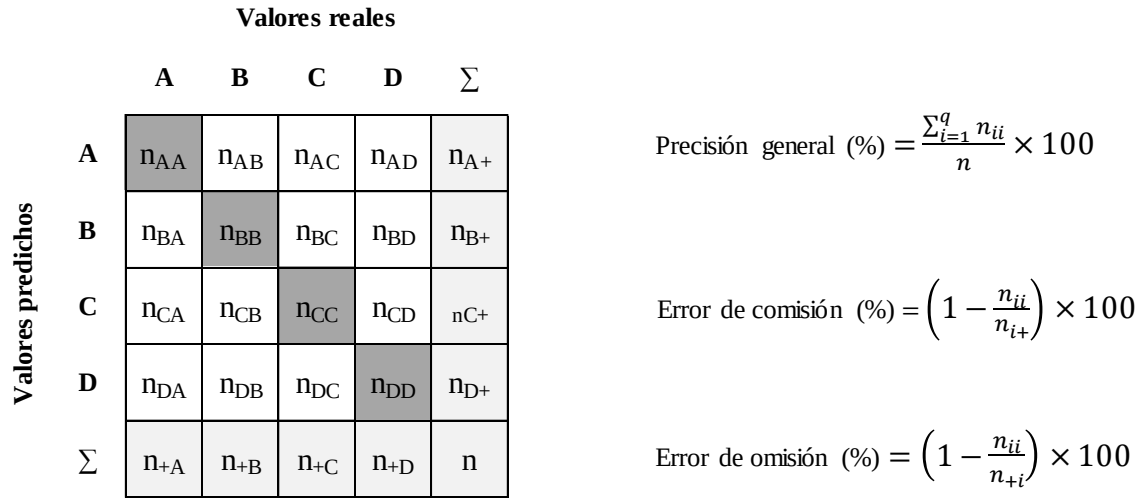

Figura 3. Ejemplo de matriz de confusión con q número total de clases y n número total de píxeles en las q clases. Los elementos n_{ii} resaltados representan la diagonal principal de la matriz en donde, los valores predichos en la clasificación coinciden con los valores observados, mientras que, los elementos fuera de la diagonal corresponden a errores de asignación de pixeles. También están indicados los cálculos de los índices de precisión utilizados que derivan de la misma.

2.5. Análisis de los cambios temporales en el uso y cobertura del suelo

Para realizar el análisis de la cobertura del suelo y de las transiciones o rotaciones entre campañas, se eligió la clasificación con mayor precisión general de cada una. Se calculó la cantidad de pixeles de cada clase de uso del suelo y su correspondiente superficie. Finalmente, se generó un mapa con las transiciones y cambios de la cobertura del suelo siguiendo el procedimiento presentado en el diagrama de la Figura 4. Como resultado, se obtuvo una imagen cuyos valores de los pixeles tienen tres cifras. Cada cifra corresponde a una campaña y su valor corresponde a una de las nueve clases de la clasificación. De esta manera en una sola imagen se puede observar la dinámica de la cobertura del suelo durante las tres campañas bajo estudio. Por ejemplo, un valor de 644 indica que un píxel en particular fue clasificado con la clase 6 en la campaña 2013-2014 y con la clase 4 en las campañas 2014-2015 y 2015-2016.

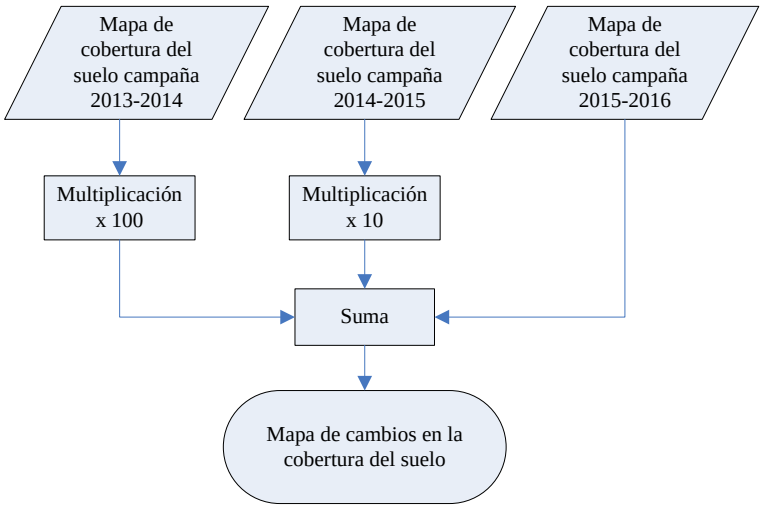

Figura 4. Diagrama de flujo del procedimiento para la generación del mapa con las transiciones de la cobertura del suelo.

3. Resultados y discusión

3.1. Campaña 2013-2014

En las clasificaciones supervisadas de la cobertura y usos del suelo utilizando como verdad de campo a los polígonos provenientes del Método de Segmentos Aleatorios se utilizaron un total de 85913 pixeles, 60139 para el entrenamiento y 25774 para la evaluación. Se logró separar las clases propuestas, pero con diferencias muy marcadas entre las clases. Tanto las clases pertenecientes a cultivos como las de recursos forrajeros, presentaron un mal desempeño, con precisiones inferiores al 55%. Sin embargo, las clases pertenecientes a forestación, afloramiento rocoso, agua permanente y zona urbana obtuvieron una mayor precisión, superiores al 80% (Tablas 2 y 3).

La baja precisión en las clasificaciones pudo deberse a la mayor variabilidad en la firma espectral que presentaban los pixeles pertenecientes a las clases con menores precisiones a lo largo del período en estudio. Por ejemplo, la variación en el tiempo de la firma espectral de los pixeles de las clases recursos forrajeros o maíz es mucho mayor que en clases como forestación o agua permanente.

Respecto a los dos procedimientos aplicados a las imágenes satelitales, es decir, utilizando subperíodos con cálculo de mediana o el período completo con cálculo de mediana y desvío estándar, ambos arrojaron resultados similares con una baja precisión general (45,8% y 50,5%, respectivamente), siendo levemente superior este último (Tablas 2 y 3).

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	Píxeles totales	Error de comisión (%)
Cultivo de invierno-Soja de 2da	372	663	286	2	454	4	16	0	30	1827	**79,6**
Soja de 1ra	710	1637	1294	274	2888	1	4	22	95	6925	**76,4**
Maíz	587	244	761	3	791	0	0	0	0	2386	**68,1**
Girasol	1	0	14	597	157	0	0	0	0	769	**22,4**
Recursos Forrajeros	1213	2117	1268	198	5634	26	37	18	63	10574	**46,7**
Forestación	31	10	0	0	146	605	52	0	0	844	**28,3**
Agua permanente	4	11	0	0	1	0	734	0	0	750	**2,1**
Afloramiento rocoso	0	19	0	0	216	0	2	753	0	990	**23,9**
Zona urbana	0	0	0	0	4	0	0	0	705	709	**0,6**
Píxeles totales	2918	4701	3623	1074	10291	636	845	793	893	**25774**	
Error de omisión (%)	**87,3**	**65,2**	**79,0**	**44,4**	**45,3**	**4,9**	**13,1**	**5,0**	**21,1**		**Precisión general (%)**
											45,8

Tabla 2. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	Píxeles totales	Error de comisión (%)
Cultivo de invierno-Soja de 2da	741	496	319	15	1321	12	18	0	24	2946	**74,8**
Soja de 1ra	563	1721	1030	187	2175	6	1	35	18	5736	**70,0**
Maíz	454	62	924	35	376	0	0	0	0	1851	**50,1**
Girasol	13	51	0	493	0	0	0	0	0	557	**11,5**
Recursos Forrajeros	1102	2321	1338	344	6295	11	37	44	70	11562	**45,6**
Forestación	13	11	0	0	58	607	40	0	4	733	**17,2**
Agua permanente	32	0	0	0	6	0	749	0	0	787	**4,8**
Afloramiento rocoso	0	39	12	0	25	0	0	714	0	790	**9,6**
Zona urbana	0	0	0	0	35	0	0	0	777	812	**4,3**
Píxeles totales	2918	4701	3623	1074	10291	636	845	793	893	**25774**	
Error de omisión (%)	**74,6**	**63,4**	**74,5**	**54,1**	**38,8**	**4,6**	**11,4**	**10,0**	**13,0**		**Precisión general (%)**
											50,5

Tabla 3. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo.

En las clasificaciones realizadas con puntos balanceados dentro de cada clase como verdad de campo, se utilizaron un total de 4320 pixeles (480 por clase), 3024 para el entrenamiento (336 por clase) y 1296 para la evaluación (144 por clase). Con esta metodología se obtuvieron resultados superadores. Tanto al utilizar subperíodos con cálculo de mediana o el período completo con cálculo de mediana y desvío estándar, la precisión general aumentó al 86,2% y 84,4%, respectivamente. No obstante, de forma similar que en el análisis anterior, las clases pertenecientes a cultivos y de recursos forrajeros fueron las que presentaron el peor desempeño (Tablas 4 y 5). Sin embargo, los errores de omisión y comisión disminuyeron considerablemente. Por ejemplo, en el cultivo de invierno-soja 2da el error de omisión bajó del 87,3% al 29,9% y el error de comisión del 79,6 al 14,4% (Tablas 2 y 4 respectivamente). En el maíz, el error de omisión disminuyó del 79% al 9% y el error de comisión del 68,1% al 14,9%. En la soja 1ra, el error de omisión pasó de 65,2% al 33,3% y el error de comisión de 76,4% a 39,2% (Tablas 2 y 4 respectivamente). En la figura 5, se presenta el mapa de la cobertura de suelo clasificado con la mediana de reflectancia superficial de 3 subperíodos y puntos balanceados como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	101	11	2	0	3	1	0	0	0	118	**14,4**
Soja de 1ra	18	96	1	1	28	0	0	0	14	158	**39,2**
Maíz	7	8	131	0	8	0	0	0	0	154	**14,9**
Girasol	4	5	3	142	6	0	0	0	0	160	**11,3**
Recursos Forrajeros	11	22	4	0	95	7	0	0	0	139	**31,7**
Forestación	2	0	0	0	0	136	1	0	0	139	**2,2**
Agua permanente	1	1	0	0	0	0	143	1	0	146	**2,1**
Afloramiento rocoso	0	1	3	1	4	0	0	143	0	152	**5,9**
Zona urbana	0	0	0	0	0	0	0	0	130	130	**0,0**
Píxeles totales	144	144	144	144	144	144	144	144	144	**1296**	
Error de omisión (%)	**29,9**	**33,3**	**9,0**	**1,4**	**34,0**	**5,6**	**0,7**	**0,7**	**9,7**		**Precisión general (%)**
											86,2

Tabla 4. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	100	15	5	1	18	4	0	0	2	145	**31,0**
Soja de 1ra	23	74	6	0	14	1	0	0	0	118	**37,3**
Maíz	3	16	125	1	12	1	0	0	0	158	**20,9**
Girasol	5	5	5	142	8	0	0	0	0	165	**13,9**
Recursos Forrajeros	8	29	0	0	88	0	0	0	0	125	**29,6**
Forestación	1	0	0	0	0	137	0	0	1	139	**1,4**
Agua permanente	2	1	0	0	0	0	144	1	0	148	**2,7**
Afloramiento rocoso	1	4	3	0	3	0	0	143	0	154	**7,1**
Zona urbana	1	0	0	0	1	1	0	0	141	144	**2,1**
Píxeles totales	144	144	144	144	144	144	144	144	144	**1296**	
Error de omisión (%)	**30,6**	**48,6**	**13,2**	**1,4**	**38,9**	**4,9**	**0,0**	**0,7**	**2,1**		**Precisión general (%)**
											84,4

Tabla 5. Matriz de confusión de la clasificación de la campaña 2013-2014 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

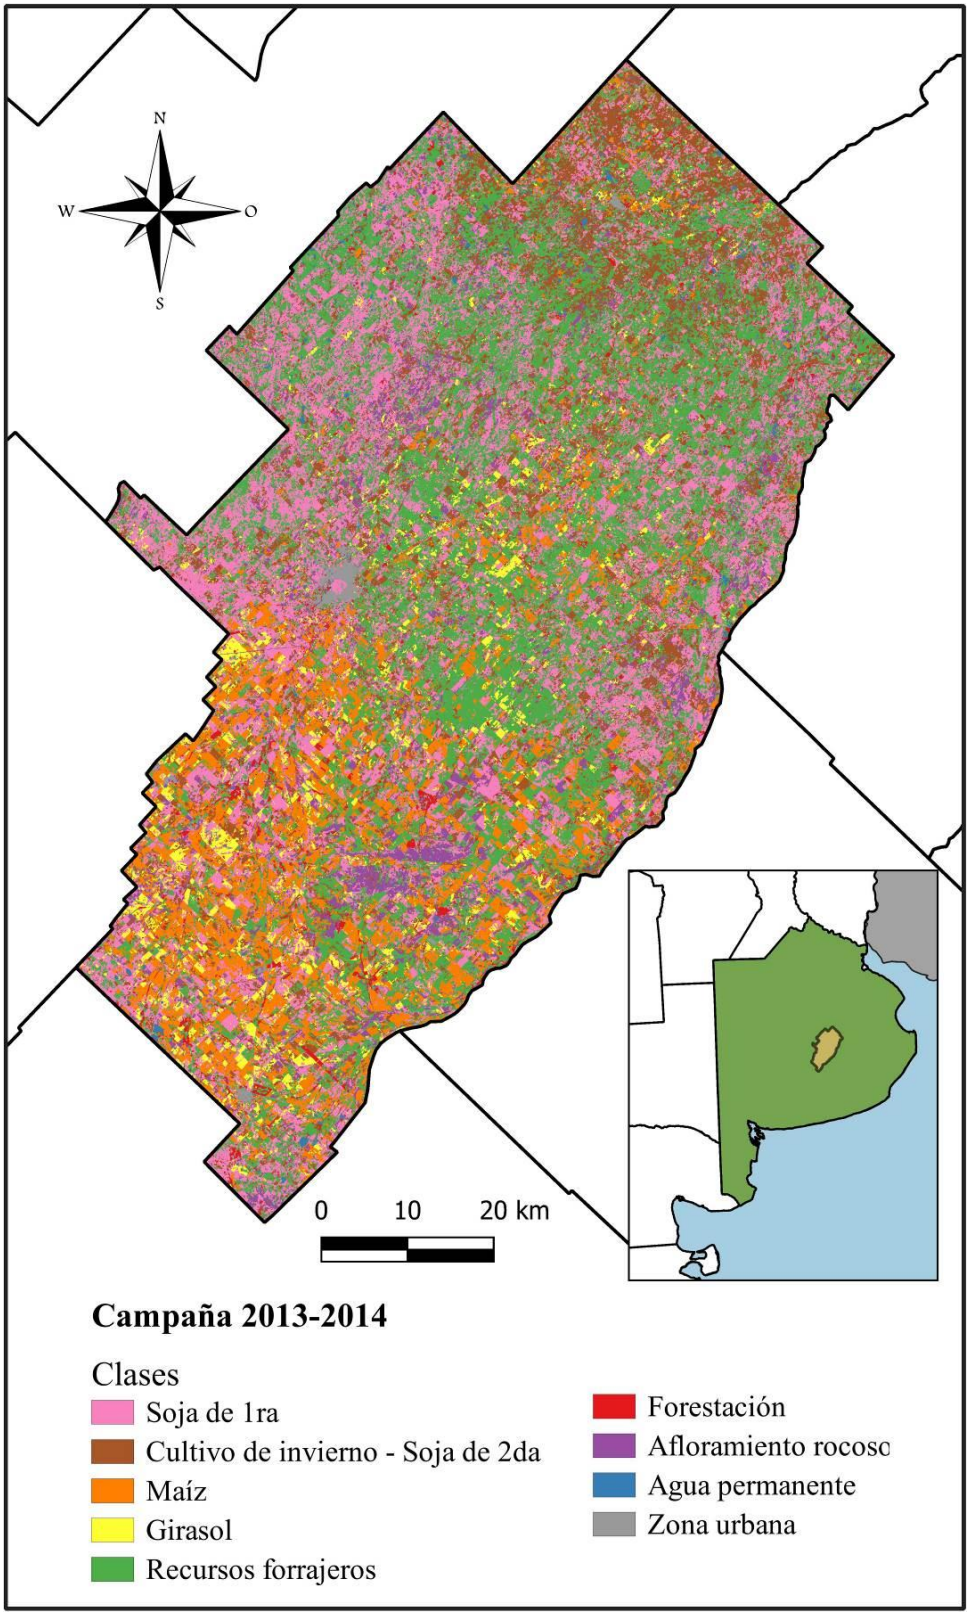

Figura 5. Mapa de la cobertura de suelo del partido de Azul para la campaña 2013-2014. Clasificación supervisada utilizando la mediana de reflectancia superficial de 3 subperíodos provenientes de imágenes Landsat 8. Como verdad de campo se emplearon puntos contenidos en los polígonos del método de segmentos aleatorios.

3.2. Campaña 2014-2015

En las clasificaciones supervisadas de la cobertura y usos del suelo utilizando como verdad de campo a los polígonos provenientes del método de segmentos aleatorios se utilizaron un total de 96140 pixeles, 67298 para el entrenamiento y 28842 para la evaluación. Utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos, presentó una precisión del 74,8%. Utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos obtuvo un 75,2%. Al igual que la campaña anteriormente descripta, tanto las clases pertenecientes a cultivos y a recursos forrajeros presentaron los mayores errores. Por ejemplo, en la clase maíz el error de omisión fue de 45,2% y 49,7% y el error de comisión de 32,1% y 17,8%. En la soja de 1ra el error de omisión fue de 39,6% y 43,1% y el error de comisión de 25,4% y 22%. En recursos forrajeros el error de omisión fue de 14,2% y 9,5% y el error de comisión de 30,3% y 32,5% (Tablas 6 y 7).

En esta campaña, se destaca la clase girasol. Cuando se utilizan los polígonos provenientes del método de segmentos aleatorios como verdad de campo, se obtienen altísimos errores, tanto de omisión como de comisión, llegando al 100% en ambos. Sin embargo, cuando se utilizan una cantidad balanceada de puntos, estos errores disminuyen prácticamente a cero (Tablas 6 y 8).

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	2624	173	34	67	187	4	12	1	0	3102	**15,4**
Soja de 1ra	338	4906	59	109	1121	0	9	32	0	6574	**25,4**
Maíz	6	243	1286	14	343	0	0	1	0	1893	**32,1**
Girasol	0	15	0	0	2	0	0	0	0	17	**100,0**
Recursos Forrajeros	568	2760	967	8	10119	31	2	60	0	14515	**30,3**
Forestación	0	0	0	0	14	488	22	1	0	525	**7,0**
Agua permanente	0	0	0	0	0	0	722	0	0	722	**0,0**
Afloramiento rocoso	16	26	0	0	0	0	0	539	0	581	**7,2**
Zona urbana	11	0	0	0	4	0	0	0	898	913	**1,6**
Píxeles totales	3563	8123	2346	198	11790	523	767	634	898	**28842**	
Error de omisión (%)	**26,4**	**39,6**	**45,2**	**100,0**	**14,2**	**6,7**	**5,9**	**15,0**	**0,0**		**Precisión general (%)**
											74,8

Tabla 6. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	2542	195	3	40	93	11	2	0	0	2886	**11,9**
Soja de 1ra	351	4618	30	124	758	0	0	40	0	5921	**22,0**
Maíz	16	1	1179	1	235	2	0	0	0	1434	**17,8**
Girasol	0	0	0	1	26	0	0	0	0	27	**96,3**
Recursos Forrajeros	654	3233	1134	32	10672	38	5	49	0	15817	**32,5**
Forestación	0	0	0	0	6	472	0	1	0	479	**1,5**
Agua permanente	0	3	0	0	0	0	760	0	0	763	**0,4**
Afloramiento rocoso	0	62	0	0	0	0	0	544	0	606	**10,2**
Zona urbana	0	11	0	0	0	0	0	0	898	909	**1,2**
Píxeles totales	3563	8123	2346	198	11790	523	767	634	898	**28842**	
Error de omisión (%)	**28,7**	**43,1**	**49,7**	**99,5**	**9,5**	**9,8**	**0,9**	**14,2**	**0,0**		**Precisión general (%)**
											75,2

Tabla 7. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	95	14	5	0	12	0	0	0	0	126	**24,6**
Soja de 1ra	8	85	2	0	12	1	0	0	0	108	**21,3**
Maíz	12	9	119	0	26	1	0	0	0	167	**28,7**
Girasol	3	7	4	145	7	2	0	1	0	169	**14,2**
Recursos Forrajeros	15	24	12	1	80	4	2	0	1	139	**42,4**
Forestación	1	2	0	0	1	138	0	0	0	142	**2,8**
Agua permanente	0	0	0	0	2	0	144	0	0	146	**1,4**
Afloramiento rocoso	10	4	3	0	5	0	0	145	0	167	**13,2**
Zona urbana	2	1	1	0	1	0	0	0	145	150	**3,3**
Píxeles totales	146	146	146	146	146	146	146	146	146	**1314**	
Error de omisión (%)	**34,9**	**41,8**	**18,5**	**0,7**	**45,2**	**5,5**	**1,4**	**0,7**	**0,7**		**Precisión general (%)**
											83,4

Tabla 8. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

En las clasificaciones realizadas con puntos balanceados dentro de cada clase como verdad de campo, se utilizaron un total de 4374 pixeles (486 por clase), 3060 para el entrenamiento (340 por clase) y 1314 para la evaluación (146 por clase). Al igual que en la campaña anterior analizada, se obtuvieron precisiones más altas en los dos procedimientos de imágenes llevados a cabo. Utilizando la mediana de reflectancia superficial de 3 subperíodos la precisión fue del 83,4% mientras que, utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período, se obtuvo un 80,5%. Sin embargo, las clases de cultivo de invierno, recursos forrajeros y soja 1ra presentaron errores de omisión y comisión incluso más altos que al utilizar los polígonos enteros. Por ejemplo, en recursos forrajeros el error de omisión fue de 45,2% y 51,4% y el error de comisión de 42,4% y 44,5% (Tablas 8 y 9). Asimismo, la clase recursos forrajeros, es la que más se confunde con las clases maíz, soja 1ra y cultivo de invierno-soja 2da. En la Figura 6, se presenta el mapa de cobertura del suelo clasificado con la mediana de reflectancia superficial de 3 subperíodos y puntos balanceados como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	101	18	7	1	9	1	1	0	2	140	**27,9**
Soja de 1ra	15	75	15	0	32	1	0	0	0	138	**45,7**
Maíz	9	13	101	0	26	1	1	0	0	151	**33,1**
Girasol	4	11	6	145	5	0	0	0	2	173	**16,2**
Recursos Forrajeros	14	20	16	0	71	3	2	1	1	128	**44,5**
Forestación	0	3	0	0	1	138	0	1	0	143	**3,5**
Agua permanente	1	1	0	0	1	0	142	0	0	145	**2,1**
Afloramiento rocoso	1	3	1	0	1	0	0	144	0	150	**4,0**
Zona urbana	1	2	0	0	0	2	0	0	141	146	**3,4**
Píxeles totales	146	146	146	146	146	146	146	146	146	**1314**	
Error de omisión (%)	**30,8**	**48,6**	**30,8**	**0,7**	**51,4**	**5,5**	**2,7**	**1,4**	**3,4**		**Precisión general (%)**
											80,5

Tabla 9. Matriz de confusión de la clasificación de la campaña 2014-2015 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

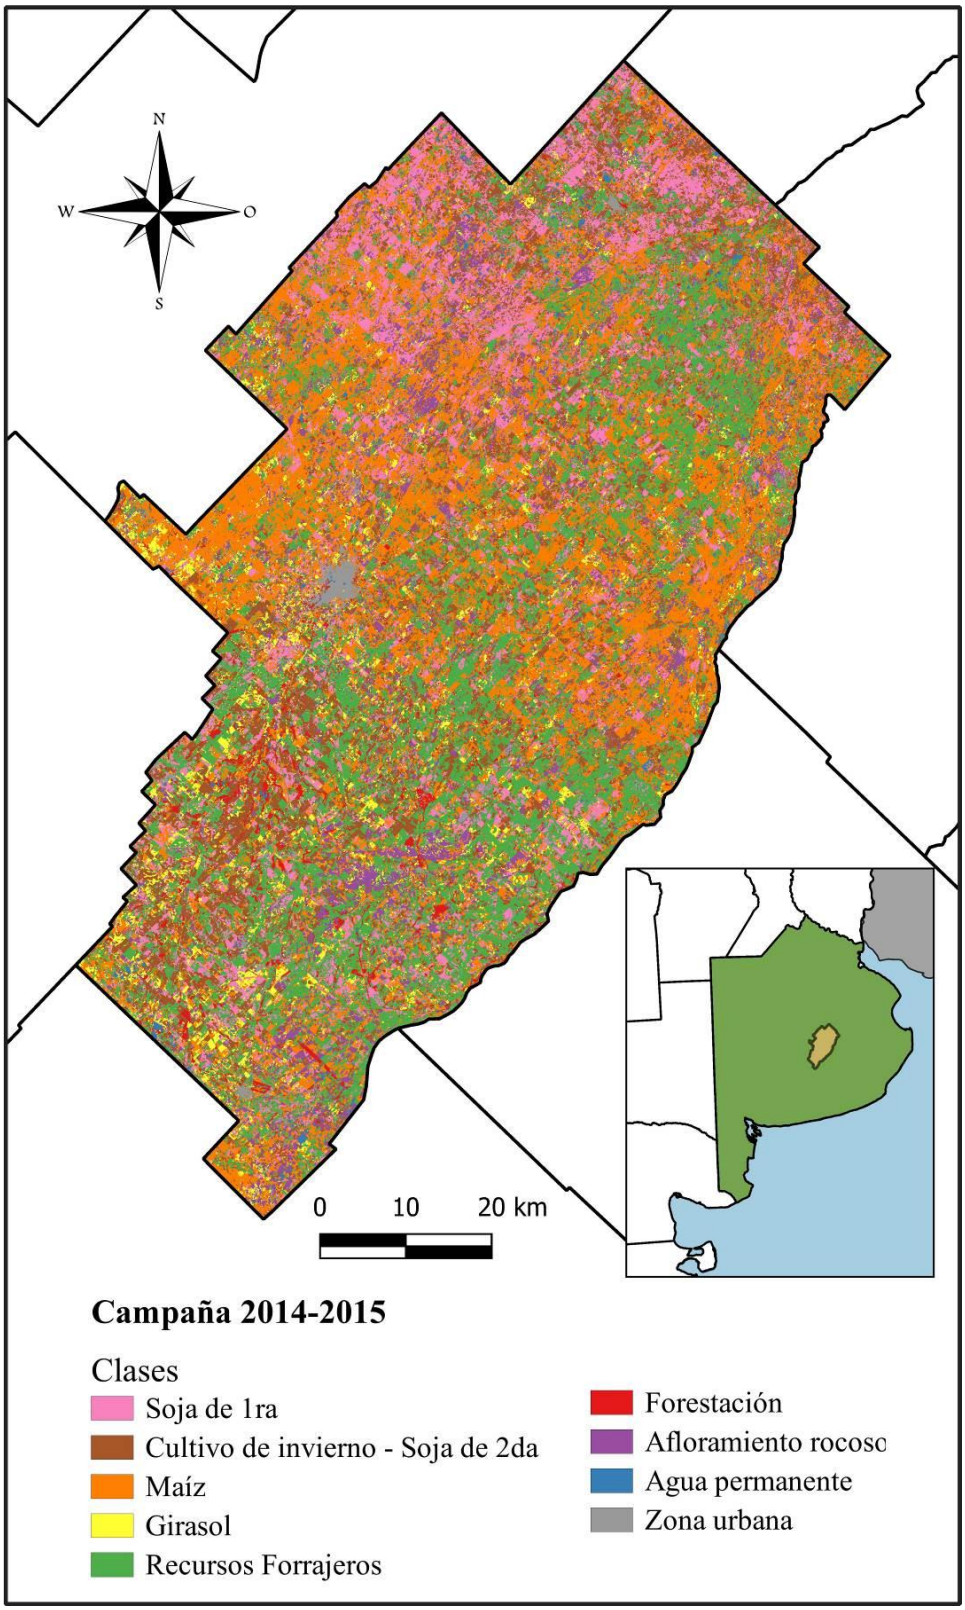

Figura 6. Mapa de la cobertura de suelo del partido de Azul para la campaña 2014-2015. Clasificación supervisada utilizando la mediana de reflectancia superficial de 3 subperíodos provenientes de imágenes

Landsat 8. Como verdad de campo se emplearon puntos contenidos en los polígonos del método de segmentos aleatorios.

3.3. Campaña 2015-2016

En las clasificaciones supervisadas de la cobertura y usos del suelo utilizando como verdad de campo a los polígonos provenientes del método de segmentos aleatorios se utilizaron un total de 84910 pixeles, 59437 para el entrenamiento y 25473 para la evaluación. La utilización de la mediana de reflectancia superficial de 3 subperíodos arrojó una precisión general baja (47,1%). Utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos se obtuvo un 47,9% de precisión. De la misma manera que en las campañas anteriormente detalladas, tanto las clases pertenecientes a cultivos y a recursos forrajeros, presentaron los mayores errores. En la clase cultivo de invierno-soja de segunda el error de omisión fue de 69,6% y 81,0% y el error de comisión de 63,6% y 71,5%. En el maíz el error de omisión fue de 73,8% y 69,1% y el error de comisión de 67,7% y 61,5%. En recursos forrajeros el error de omisión fue de 41,5% y 47% y el error de comisión de 53,9% y 51,8% (Tablas 10 y 11). En la clase girasol se obtuvo altísimos errores llegando al 100% en omisión y comisión. A su vez, en la clasificación que se utilizó la mediana de reflectancia superficial de 3 subperíodos, la clase afloramiento rocoso presentó un alto error de omisión de 66,2%, y el error de comisión fue de 16,9% (Tabla 10).

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	958	631	90	3	821	0	115	11	0	2629	**63,6**
Soja de 1ra	619	2645	402	180	2480	8	0	0	1	6335	**58,2**
Maíz	173	186	526	122	620	0	0	0	0	1627	**67,7**
Girasol	124	96	2	0	89	4	0	0	0	315	**100,0**
Recursos Forrajeros	1274	3399	976	423	5682	23	30	405	111	12323	**53,9**
Forestación	0	2	0	0	0	506	0	0	3	511	**1,0**
Agua permanente	5	0	0	0	0	0	430	0	0	435	**1,1**
Afloramiento rocoso	2	0	14	0	27	0	0	212	0	255	**16,9**
Zona urbana	0	0	0	0	0	1	0	0	1042	1043	**0,1**
Píxeles totales	3155	6959	2010	728	9719	542	575	628	1157	**25473**	
Error de omisión (%)	**69,6**	**62,0**	**73,8**	**100,0**	**41,5**	**6,6**	**25,2**	**66,2**	**9,9**		**Precisión general (%)**
											47,1

Tabla 10. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana de reflectancia superficial de 3 subperíodos y polígonos del método de segmentos aleatorios como verdad de campo.

En las clasificaciones realizadas con puntos balanceados dentro de cada clase como verdad de campo, se utilizaron un total de 5850 pixeles (650 por clase), 4095 para el entrenamiento (455 por clase) y 1755 para la evaluación (195 por clase). Al igual que en los dos períodos anteriores analizados, las precisiones de las clasificaciones aumentaron de manera significativa. La mayor precisión (82,5%) se obtuvo utilizando el período completo con cálculo de mediana y desvío estándar (Tablas 12 y 13).

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	880	916	189	93	976	2	28	0	0	3084	**71,5**
Soja de 1ra	1346	3514	983	469	2923	4	0	1	7	9247	**62,0**
Maíz	232	457	906	64	682	0	0	12	1	2354	**61,5**
Girasol	218	116	4	0	40	0	0	0	0	378	**100,0**
Recursos Forrajeros	1955	2585	846	189	5217	22	5	2	1	10822	**51,8**
Forestación	0	0	0	0	0	1042	0	0	0	1042	**0,0**
Agua permanente	2	0	0	0	1	0	878	0	0	881	**0,3**
Afloramiento rocoso	0	0	0	0	6	0	44	754	0	804	**6,2**
Zona urbana	0	2	1	0	1	0	0	0	984	988	**0,4**
Píxeles totales	4633	7590	2929	815	9846	1070	955	769	993	**29600**	
Error de omisión (%)	**81,0**	**53,7**	**69,1**	**100,0**	**47,0**	**2,6**	**8,1**	**2,0**	**0,9**		**Precisión general (%)**
											47,9

Tabla 11. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y polígonos del método de segmentos aleatorios como verdad de campo.

Con respecto a los errores por ejemplo, la clase maíz, disminuyó a 12,8% el error de omisión y a 37,7% el error de comisión (Tabla 13). También se destacan las clases girasol y afloramiento rocoso que al utilizar el procedimiento de puntos balanceados, obtuvieron mejoras muy notables, con errores de omisión de 13,8% y 0% respectivamente y errores de comisión de 15,6% y 3,9% respectivamente (Tabla 13). En la figura 7, se presenta el mapa de cobertura de suelo clasificado con la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos balanceados como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	108	11	4	1	13	0	0	0	0	137	**21,2**
Soja de 1ra	11	105	7	3	19	0	2	0	0	147	**28,6**
Maíz	15	24	164	4	21	0	2	1	0	231	**29,0**
Girasol	38	15	3	185	22	3	0	102	51	419	**55,8**
Recursos Forrajeros	21	34	14	1	116	1	0	9	0	196	**40,8**
Forestación	0	1	0	0	1	191	0	0	0	193	**1,0**
Agua permanente	0	2	2	1	0	0	190	2	0	197	**3,6**
Afloramiento rocoso	2	3	1	0	3	0	1	81	0	91	**11,0**
Zona urbana	0	0	0	0	0	0	0	0	144	144	**0,0**
Píxeles totales	195	195	195	195	195	195	195	195	195	**1755**	
Error de omisión (%)	**44,6**	**46,2**	**15,9**	**5,1**	**40,5**	**2,1**	**2,6**	**58,5**	**26,2**		**Precisión general (%)**
											73,2

Tabla 12. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana de reflectancia superficial de 3 subperíodos y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

Clase	*Cultivo de invierno-Soja de 2da*	*Soja de 1ra*	*Maíz*	*Girasol*	*Recursos Forrajeros*	*Forestación*	*Agua permanente*	*Afloramiento rocoso*	*Zona urbana*	**Píxeles totales**	**Error de comisión (%)**
Cultivo de invierno-Soja de 2da	128	14	6	0	30	1	0	0	0	179	**28,5**
Soja de 1ra	10	103	6	3	17	0	1	0	0	140	**26,4**
Maíz	24	30	170	18	26	0	3	0	2	273	**37,7**
Girasol	8	8	7	168	7	1	0	0	0	199	**15,6**
Recursos Forrajeros	24	30	4	6	111	1	2	0	0	178	**37,6**
Forestación	0	3	0	0	1	191	0	0	0	195	**2,1**
Agua permanente	0	3	1	0	1	0	188	0	0	193	**2,6**
Afloramiento rocoso	1	3	1	0	2	0	1	195	0	203	**3,9**
Zona urbana	0	1	0	0	0	1	0	0	193	195	**1,0**
Píxeles totales	195	195	195	195	195	195	195	195	195	**1755**	
Error de omisión (%)	**34,4**	**47,2**	**12,8**	**13,8**	**43,1**	**2,1**	**3,6**	**0,0**	**1,0**		**Precisión general (%)**
											82,5

Tabla 13. Matriz de confusión de la clasificación de la campaña 2015-2016 utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período y puntos contenidos en los polígonos del método de segmentos aleatorios como verdad de campo.

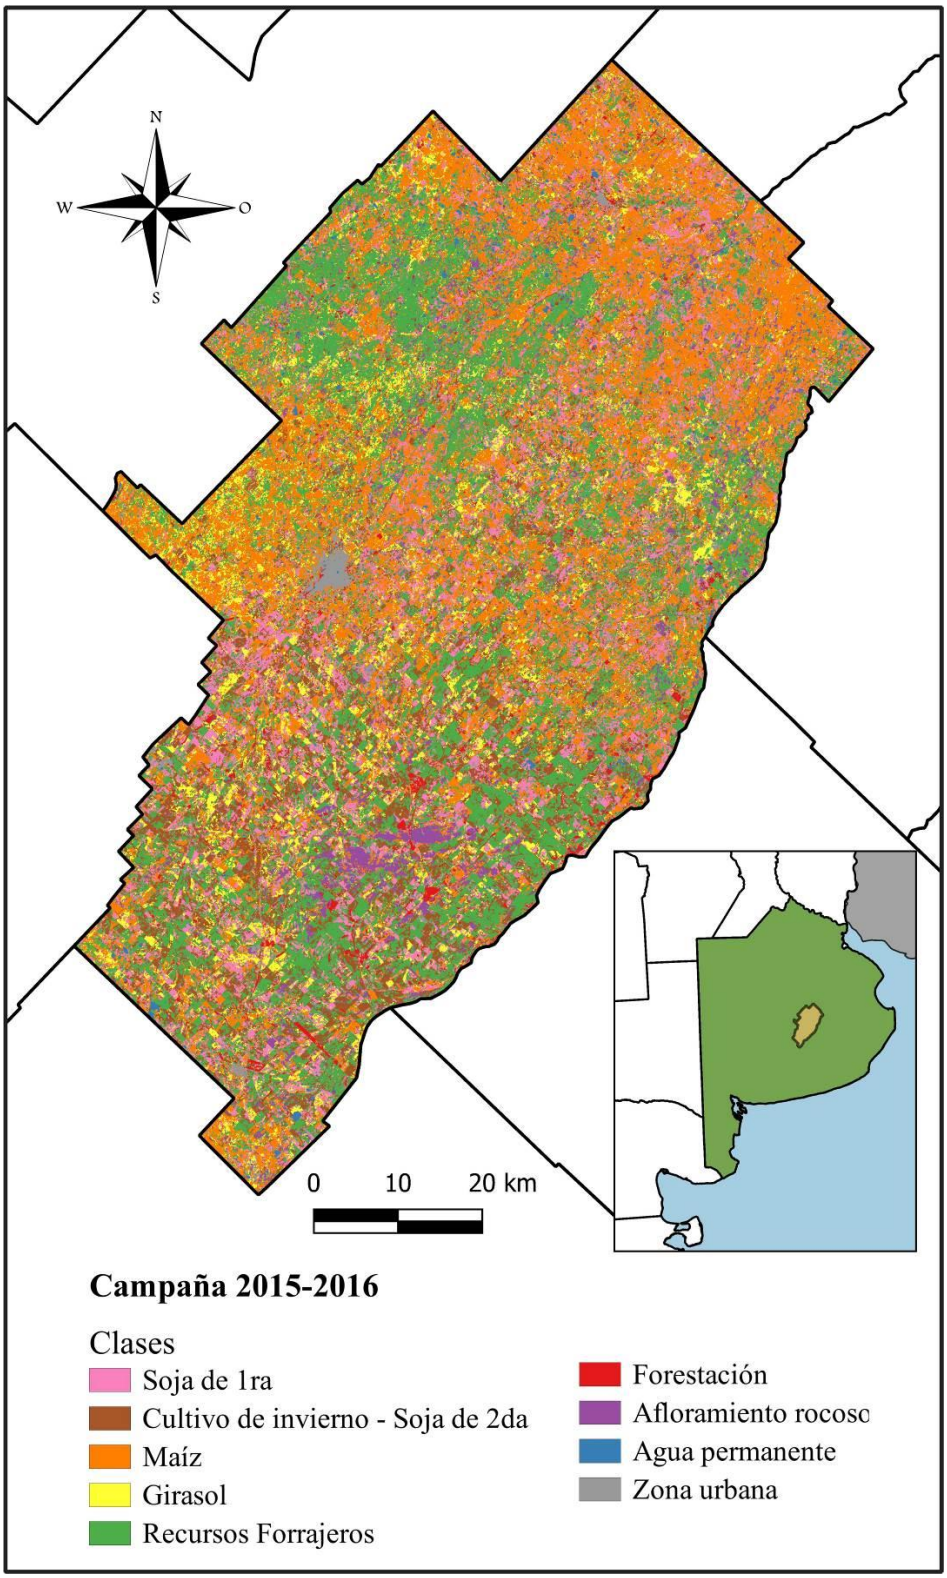

Figura 7. Mapa de la cobertura de suelo del partido de Azul para la campaña 2015-2016. Clasificación supervisada utilizando la mediana y el desvío estándar de reflectancia superficial de todo el período provenientes de imágenes Landsat 8. Como verdad de campo se emplearon puntos contenidos en los polígonos del método de segmentos aleatorios.

3.4 Comparación entre campañas

Las clasificaciones realizadas utilizando los polígonos provenientes del Método de Segmentos Aleatorios como verdad de campo presentaron bajas precisiones en las tres campañas analizadas. Un factor que puede explicar esta tendencia, está asociado al algoritmo de clasificación Random Forest per sé. Las clases que tienen pocos datos para el entrenamiento, en ocasiones presentan una baja precisión en la clasificación. Si bien el algoritmo Random Forest tiene baja sensibilidad a la reducción del tamaño del conjunto de datos para entrenamiento, la precisión disminuye abruptamente al alcanzar una reducción del 70% en el mismo (Rodríguez-Galiano *et al.*, 2012). Otro factor a considerar que puede explicar la baja precisión obtenida en las clasificaciones es la utilización de información de campo equivocada en el entrenamiento. Esto contribuiría a aumentar la variabilidad dentro de las categorías y, por lo tanto, tendría un efecto directo sobre la precisión de las clasificaciones (Foody, 2002). El algoritmo Random Forest es poco sensible al ruido, sin embargo, si se supera el umbral de 20%, el error aumenta exponencialmente (Rodriguez-Galiano *et al.*, 2012).

Sin embargo, como se mencionó anteriormente, la utilización de puntos balanceados como verdad de campo, logró aumentar significativamente la precisión general de la clasificación en todas las campañas estudiadas (Tabla 14). El algoritmo Random Forest, en determinadas situaciones es muy sensible al desequilibrio muestral. La utilización de datos de entrenamiento desequilibrados (distinto número de muestras por cada clase), tiende a generar árboles que favorecen la asignación a las clases mayoritarias y dificultan la correcta clasificación de las clases menos frecuentes (Arantzazu Larrañaga y Álvarez Mozos, 2017). A su vez, en dos campañas (2013-2014 y 2014-2015) la máxima precisión se obtuvo utilizando los subperíodos con cálculo de mediana y la campaña 2015-2016 utilizando el período completo con cálculo de mediana y desvío estándar (Tabla 14).

Precision general (%)		***Poligonos aleatorios***	***Puntos aleatorios balanceados***
Campaña 2013-2014	***Medianas en 3 subperíodos***	45,8	86,2
	Mediana y desvío de todo el período	50,5	84,4
Campaña 2014-2015	***Medianas en 3 subperíodos***	74,8	83,4
	Mediana y desvío de todo el período	75,2	80,5
Campaña 2015-2016	***Medianas en 3 subperíodos***	47,1	73,2
	Mediana y desvío de todo el período	-	82,5

Tabla 14. Precisión general de todas las combinaciones de procedimientos y campañas.

En la Tabla 15 se presenta la precisión general, el error de omisión y el error de comisión de todas las combinaciones de procedimientos y campañas para dos grupos de clases. Por un lado, un grupo que incluye las clases cuya información de verdad terrestre provienen del método de segmentos aleatorios (cultivos y recursos forrajeros) y por otro lado un grupo de clases cuya información de verdad terrestre provienen de fotointerpretación (forestación, afloramiento rocoso, agua permanente y zona urbana). En el grupo de clases pertenecientes a forestación, afloramiento rocoso, agua permanente y zona urbana se logra una clasificación con mayor precisión en comparación con el grupo de clases pertenecientes a cultivos y recursos forrajeros. Esta tendencia se puede observar en las tres campañas por igual. Esto podría estar asociado, por un lado, a que las clases pertenecientes a forestación, afloramiento rocoso, agua permanente y zona urbana no tendrían un cambio importante en el tiempo (tanto intra como interanual), como si existe en los cultivos y recursos forrajeros. Por otro lado, en el grupo de clases perteneciente a cultivos y recursos forrajeros la información de verdad de campo aportada por el método de segmentos aleatorios podría contener errores.

			Precisión (%)	***Error de omisión***	***Error de comisión***
Campaña 2013-2014	***Medianas en 3 subperíodos***	***Cultivos+Recursos forrajeros***	78,5	21,5	22,5
		Forestación+afloramiento rocoso+agua permanente+zona urbana	95,8	4,2	2,6
	Mediana y desvío de todo el período	***Cultivos+Recursos forrajeros***	73,5	26,5	25,6
		Forestación+afloramiento rocoso+agua permanente+zona urbana	98,1	1,9	3,4
Campaña 2014-2015	***Medianas en 3 subperíodos***	***Cultivos+Recursos forrajeros***	71,8	28,2	26,1
		Forestación+afloramiento rocoso+agua permanente+zona urbana	97,9	2,1	5,5
	Mediana y desvío de todo el período	***Cultivos+Recursos forrajeros***	67,5	32,5	32,5
		Forestación+afloramiento rocoso+agua permanente+zona urbana	96,7	3,3	3,3
Campaña 2015-2016	***Medianas en 3 subperíodos***	***Cultivos+Recursos forrajeros***	69,5	30,5	40,0
		Forestación+afloramiento rocoso+agua permanente+zona urbana	77,7	22,3	3,0
	Mediana y desvío de todo el período	***Cultivos+Recursos forrajeros***	69,7	30,3	29,8
		Forestación+afloramiento rocoso+agua permanente+zona urbana	98,3	1,7	2,4

Tabla 15. Precisión general, error de omisión y error de comisión de todas las combinaciones de procedimientos y campañas para dos grupos de clases.

3.5 Proporción de usos del suelo por campaña

De los datos obtenidos a partir de la estimación de superficie utilizando el método de Olofsson *et al.* (2014) se desprende que en la campaña 2013-2014 la superficie cubierta por cultivos fue del 61% ± 5% (402.782 ha ± 18.477 ha), mientras que la superficie cubierta por recursos forrajeros fue del 27% ± 11% (177.207 ha ± 18.666 ha) (Tabla 16). El cultivo con más superficie implantada fue la soja, ya que soja de primera y segunda sumadas alcanzó el 44% ± 12% de la superficie. El cultivo de maíz y girasol ocuparon un 11% ± 11% y 4% ± 10% de cobertura, respectivamente (Tabla 17).

En la campaña 2014-2015 el área cubierta por cultivos ascendió a 66% ± 4% (436.896 ha ± 17.201 ha), mientras que la superficie de recursos forrajeros se redujo al 21% ± 12% del partido (138.640 ha ± 17.168 ha) (Tabla 16). El cultivo de soja de primera y de segunda juntas disminuyó su área de cobertura con respecto a la campaña anterior, sin embargo, continúo siendo el cultivo con mayor superficie (38% ± 12%), seguido por el maíz (que incrementó su superficie a 23% ± 10%) y el girasol (4% ± 10%) (Tabla 17).

En la campaña 2015-2016, la superficie cubierta por cultivos alcanzó el 67% ± 4% (439.784 ha ± 16.083 ha) y la cubierta por recursos forrajeros el 24% ± 10% (159.040 ha ± 15.972 ha), valores similares a la campaña del año anterior (Tabla 16). La cobertura de soja de primera y de segunda se redujo levemente, ocupando el 37% ± 11% de la superficie del partido, mientras que el maíz presentó un área igual a 19% ± 10%. La cobertura de girasol, por su parte, tuvo un incremento que alcanzó el 11% ± 12% del área (Tabla 17).

	Campaña											
	2013-2014				***2014-2015***				***2015-2016***			
Clase	***Superficie***		***Intervalo de confianza***		***Superficie***		***Intervalo de confianza***		***Superficie***		***Intervalo de confianza***	
	(ha)	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***
Cultivos	402782	61	18477	5	436896	66	17202	4	439784	67	16084	4
Recursos Forrajeros	177207	27	18666	11	138640	21	17169	12	159040	24	15973	10
Otros	77154	12	9291	12	81607	12	6993	9	58320	9	4620	8

Tabla 16. Superficie e intervalo de confianza de tres grupos de clases, estimado con el método de Olofsson *et al.* (2014), para cada campaña bajo estudio.

	Campaña											
	2013-2014				***2014-2015***				***2015-2016***			
Clase	***Superficie***		***Intervalo de confianza***		***Superficie***		***Intervalo de confianza***		***Superficie***		***Intervalo de confianza***	
	(ha)	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***	***(ha)***	***(%)***
Cultivo invierno-Soja de 2da	130203	20	14962	11	126549	19	14892	12	107594	16	13184	12
Soja de 1ra	157942	24	19959	13	126392	19	15539	12	136004	21	14800	11
Maíz	71983	11	8047	11	148793	23	15261	10	123673	19	11802	10
Girasol	25974	4	2649	10	28138	4	2874	10	69596	11	8172	12
Recursos forrajeros	187733	29	20314	11	147650	22	18774	13	161592	25	16390	10
Forestación	23316	4	8067	35	18831	3	5394	29	13510	2	2322	17
Agua permanente	6288	1	222	4	9658	1	3312	34	14270	2	3923	27
Afloramiento rocoso	31435	5	1259	4	38907	6	2323	6	21133	3	590	3
Zona urbana	22268	3	7992	36	10406	2	2364	23	9723	1	1797	18

Tabla 17. Superficie e intervalo de confianza de cada clase, estimado con el método de Olofsson *et al.* (2014), para cada campaña bajo estudio.

Del total de la superficie cubierta en el partido de Azul, el 93,4% presentó algún tipo de cambio de cobertura o uso del suelo a lo largo de las tres campañas bajo estudio. El 6,6% restante ha permanecido en la misma clase de cobertura. El 51,4% del área presentó un cambio de uso, combinando cultivos con recursos forrajeros. A su vez, el 24,1% del área tuvo algún tipo de rotación, pero entre distintos tipos de cultivos. En el grupo que presentó cambios en el uso y la cobertura del suelo se incluye el subgrupo "Otros" donde se agruparon a todos los pixeles que se clasificaron como forestación, agua permanente, afloramientos rocosos y/o zona urbana en al menos una campaña (Tabla 18). En la Figura 8, se puede observar el mapa de cambio en el uso y la cobertura del suelo, donde las áreas en color no han sufrido ningún cambio durante las tres campañas. En cambio, el área en blanco representa aquellas situaciones en donde se ha identificado algún tipo de cambio en al menos una de las campañas (el 93,4% del partido).

		Cantidad de píxeles	**Superficie**	
			(%)	**(ha)**
Sin cambios	***Cultivos***	82072	1,1%	7386
	Recursos forrajeros	235993	3,2%	21239
	Forestación-Agua permanente-Afloramiento rocoso-Zona urbana	166190	2,3%	14957
Con cambios	**Solo cultivos**	1761116	24,1%	158500
	Cultivos-Recursos forrajeros	3755853	51,4%	338027
	Otros	1300366	17,8%	117034
Total		7301590	100%	657143

Tabla 18. Cantidad de píxeles y superficie de distintos grupos de clases que han mostrado o no cambios en la cobertura de suelo.

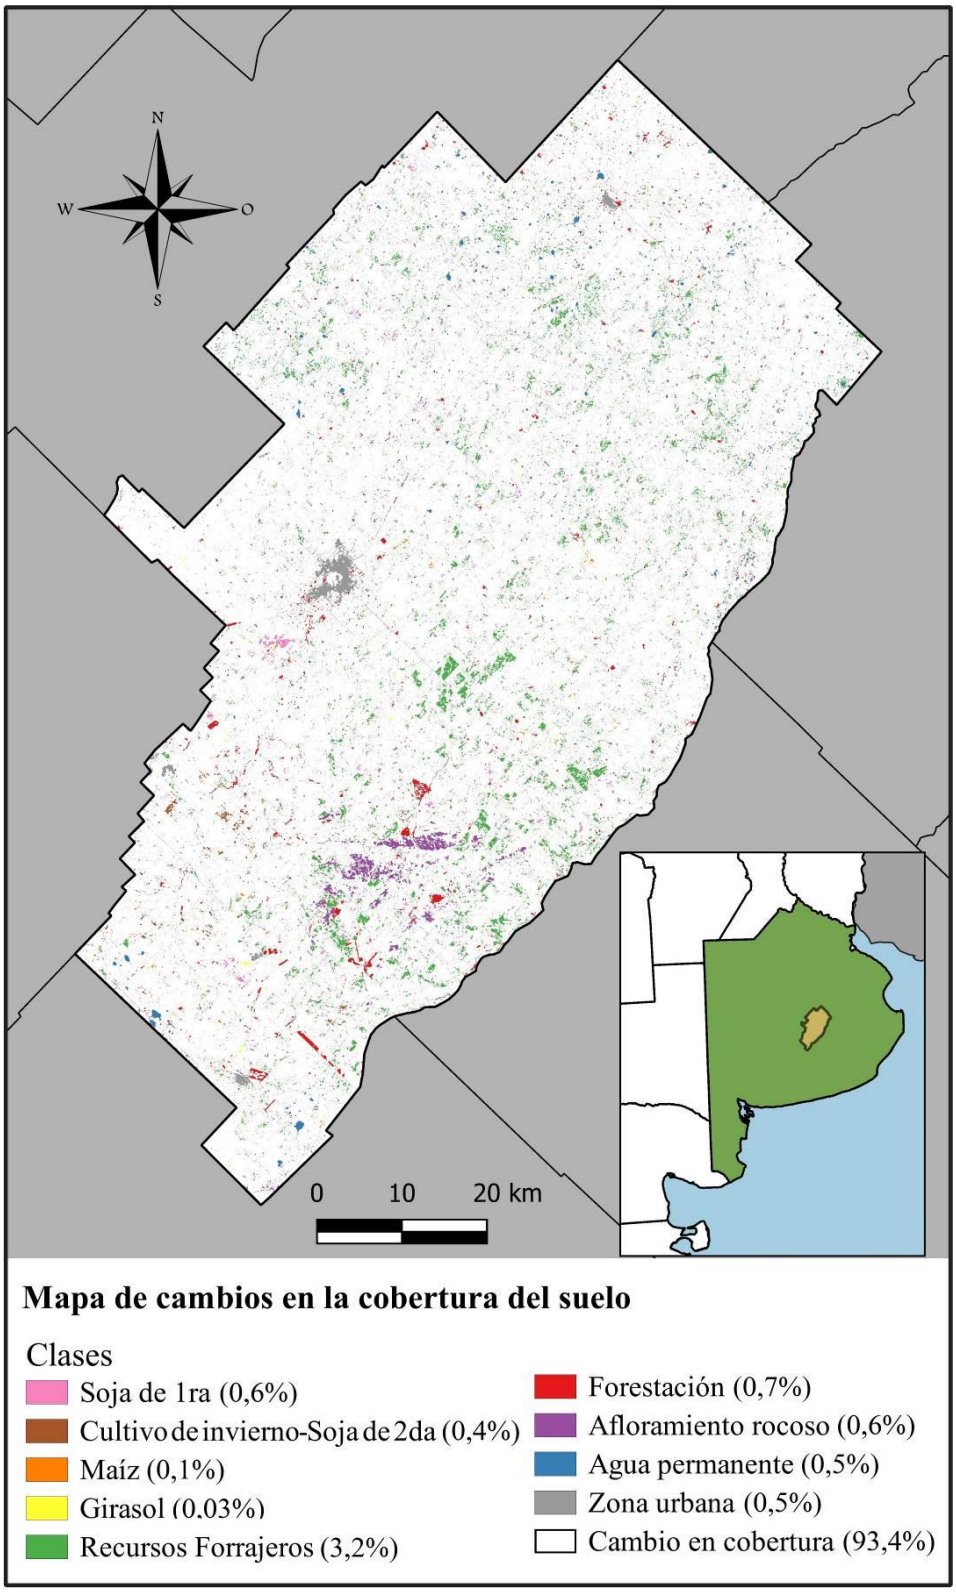

Figura 8. Mapa de cambios en la cobertura del suelo durante las campañas 2013-2014, 2014-2015 y 2015-2016. Las áreas en color no han presentado cambios en la cobertura del suelo. Las áreas en blanco si han presentado algún cambio de cobertura al menos en una campaña. En cada clase se indica la proporción de la superficie que ocupa la misma.

En la Tabla 19 se presentan las transiciones de cobertura terrestre ocurridas entre las campañas 2013-2014/2014-2015 y 2014-2015/2015-2016 para las clases de cultivos y recursos forrajeros. Entre la campaña 2013-2014 y la campaña 2014-2015 las tres transiciones más representantes fueron: recursos forrajeros a maíz con el 10,1% de superficie (66437 ha), soja de primera a maíz con el 9,4% (61574 ha) y recursos forrajeros a cultivo de invierno-soja de segunda con el 5,6% (37063 ha). Entre la campaña 2014-2015 y la campaña 2015-2016 las tres transiciones más representantes fueron: maíz a recursos forrajeros con el 8,4% de superficie (54937 ha), recursos forrajeros a maíz con el 5% (32529 ha) y cultivo de invierno-soja de segunda a maíz con el 4,9% (32266 ha). A su vez, los monocultivos, como por ejemplo soja de primera, maíz y girasol, abarcaron un área muy pequeña del 0,63%, 0,10% y 0,03% respectivamente. Mientras que, el área dedicada exclusivamente a los recursos forrajeros durante las tres campañas fue del 3,23% (Figura 8). Sin embargo, la superficie de muchas de las transiciones entre clases resultó menor al intervalo de confianza estimado, por lo tanto, pueden deberse a errores aleatorios de las clasificaciones.

		Transición entre clases			
		2013-2014 / 2014-2015		2014-2015 / 2015-2016	
		Superficie		Superficie	
		(%)	(ha)	(%)	(ha)
Recursos Forrajeros	Recursos Forrajeros	9,9	64794	8,3	54214
	Cultivo invierno - Soja de 2da	5,6	37063	4,2	27337
	Soja de 1ra	3,9	25629	4,8	31477
	Maíz	10,1	66437	5,0	32529
	Girasol	1,1	7163	2,3	15049
Cultivo invierno-Soja de 2da	Recursos Forrajeros	3,7	24117	4,3	28191
	Cultivo invierno - Soja de 2da	3,2	20700	2,6	17349
	Soja de 1ra	2,9	18991	3,4	22540
	Maíz	3,9	25891	4,9	32266
	Girasol	0,7	4534	1,5	10120
Soja de 1ra	Recursos Forrajeros	5,1	33186	3,5	22934
	Cultivo invierno-Soja de 2da	4,5	29309	1,6	10777
	Soja de 1ra	4,3	28454	2,3	15114
	Maíz	9,4	61574	4,8	31214
	Girasol	1,6	10317	1,3	8477
Maíz	Recursos Forrajeros	4,4	28980	8,4	54937
	Cultivo invierno - Soja de 2da	2,5	16691	2,1	13800
	Soja de 1ra	1,6	10383	3,3	21883
	Maíz	1,3	8280	9,2	60326
	Girasol	0,6	4206	2,6	17217
Girasol	Recursos Forrajeros	1,3	8609	1,5	9726
	Cultivo invierno - Soja de 2da	0,9	5914	0,7	4271
	Soja de 1ra	0,7	4271	0,7	4403
	Maíz	0,8	5520	1,2	7754
	Girasol	0,2	1577	0,4	2891

Tabla 19. Superficie de las transiciones ocurridas entre las clases de coberturas en el período analizado (2013-2016).

4. Conclusión

La utilización de los polígonos provenientes del Método de Segmentos Aleatorios como verdad de campo para la realización de una clasificación supervisada en el partido de Azul, resultó en una precisión general baja. Sin embargo, al realizar una selección aleatoria de puntos de la misma cantidad para cada una de las clases, incrementó en gran medida la precisión general de la clasificación, con la consecuente reducción de los errores de omisión y de comisión, obteniendo buenos resultados.

Asimismo, al utilizar la mediana de reflectancia superficial de 3 subperíodos (primavera-verano-otoño) para la clasificación, se lograron mejores precisiones al separar las clases pertenecientes a cultivos. Mientras que, al utilizar la mediana y el desvío estándar de reflectancia superficial de todo el período, se obtuvieron mejores resultados para separar las clases de forestación, agua permanente, afloramiento rocoso y zona urbana.

El área cubierta por cultivos fue superior a la cubierta por recursos forrajeros en las tres campañas estudiadas. El promedio de superficie cubierta por cultivos fue del 65% (±4) mientras que la cubierta por recursos forrajeros fue del 24% (±11). A su vez, el cultivo de soja (primera y segunda juntas) fue la clase de cobertura más frecuente en las 3 campañas, con el 40% (±12) de superficie en promedio. Estos datos contrastan con las estimaciones del MAGyP del año 2015, donde muestran que el 32,2% de la superficie del partido está cubierta por cultivos, mientras que el 54,0% está cubierta por recursos forrajeros.

Del total de la superficie bajo estudio, el 93,4% presentó algún tipo de cambio en el uso y cobertura del suelo, mientras que el 6,6% restante ha permanecido en la misma clase de cobertura a lo largo de las tres campañas. Entre la campaña 2013-2014 y la campaña 2014-2015 las tres transiciones más representantes fueron: recursos forrajeros a maíz con el 10,1% de superficie, soja de primera a maíz con el 9,4% y recursos forrajeros a cultivo de invierno-soja de segunda con el 5,6%. Entre la campaña 2014-2015 y la campaña 2015-2016 las tres transiciones más representantes fueron: maíz a recursos forrajeros con el 8,4% de superficie, recursos forrajeros a maíz con el 5% y cultivo de invierno-soja de segunda a maíz con el 4,9%. Se observaron superficies de transiciones entre clases que resultaron menores al intervalo de confianza estimado. Para tener una mayor certeza de esas transiciones, sería importante contar con una mayor cantidad de muestras para evaluación, que permitiría reducir el intervalo de confianza de la estimación.

Con el objetivo de mejorar la separación de clases, principalmente en aquellas donde se observó una mayor confusión, los resultados alcanzados en este trabajo podrían complementarse con estudios que incluyan o combinen en las clasificaciones índices espectrales de vegetación, como así también imágenes de otros sensores. Imágenes de sensores de distinta tecnología, como radar de apertura sintética, o imágenes ópticas, pero con mayor resolución espacial y temporal, pueden aportar información adicional a la clasificación. Asimismo, la aplicación de diferentes métodos de clasificación de imágenes, como por ejemplo la clasificación basada en objetos, podría mejorar la

separabilidad de clases. En este método de clasificación mencionado, el análisis está basado en la información que tiene un conjunto de pixeles con características similares no solo espectralmente sino también en tamaño, textura o forma. A su vez, se sugiere que, en estudios posteriores, se realice un análisis contemplando la extensión superficial total que abarca el método de segmentos aleatorios como así también el período temporal hasta la actualidad. Se podrá estudiar si existen áreas donde la utilización de la información del método de segmentos aleatorios permita alcanzar mejores resultados o si presenta una mejora a medida que avanza el período analizado.

La generación de mapas de este tipo de manera periódica permitiría caracterizar a nivel de lote aspectos como la rotación de cultivos y la intensidad de uso del suelo, cuestiones importantes relacionadas con la sustentabilidad del manejo agrícola. A su vez, ayudaría a la planificación y toma de decisiones a distintas escalas, tanto local, regional o nacional. Por ejemplo, permitiendo la planificación del almacenamiento y transporte, como así también la estimación de ingresos fiscales o generación de divisas.

5. Bibliografía

Arantzazu Larrañaga, A. y Álvarez Mozos, J. (2017). Influencia del equilibrio en el tamaño de muestra de entrenamiento en la clasificación de cultivos obtenida mediante Random Forests. En XVII Congreso de la Asociación Española de Teledetección (pp. 66-70). Murcia: Editorial Universitat Politècnica de València.

Bagnato, C., Conde, C., Noe, Y., Caride, C., Baeza, S., Paoli, H., Vallejos, M., Gallego, F., Vale, L., Amdan, L., Elena, H., Texeira, M., Mosciaro, J., Ciuffoli, L., Morales, C., Baldasini, P., Aguiar, S., Arocena, M.D., Volante, J.N., Paruelo, J.M. (2012). Utilización de firmas espectrales de alta resolución temporal para la elaboración de mapas de uso agrícola y estimaciones de superficie cultivada a escala de lote en Argentina y Uruguay. En Congreso Argentino de Teledetección (pp. 18-21). Córdoba.

Beget, M. E., Di Bella, C. (2014). El comportamiento espectral de las cubiertas vegetales. En Percepción remota y sistemas de información geográfica. Sus aplicaciones en Agronomía y Ciencias Ambientales (pp187-205). Buenos Aires: Ediciones Hemisferio Sur.

Breiman, L. (2001). Random forests. Machine learning, 45(1), 5-32.

Chuvieco, E. (1990). Tratamiento digital de imágenes. En Fundamentos de teledetección espacial (pp205-374). Madrid: Rialp.

Congalton, R. (1991). A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment 37, 35-46.

Della Valle, C., y de Nuria Dufour, M. (2013). Utilización de tecnología satelital para determinar la estimación de superficies agrícolas: Método de segmentos aleatorios.

Anais XVI Simpósio Brasileiro de Sensoriamento Remoto (pp. 128-134). Foz do Iguaçu.

Díaz Gómez, A.R. y Gaspari, F. J. (2017). Cambio de cobertura y uso del suelo en la zona ribereña en cuencas subtropicales del noroeste argentino. Quebracho-Revista de Ciencias Forestales, 25(1-2), 28-39.

Fandos, C., Baldrés, J. I. C., Scandaliaris, P., Soria, F. J., Gamboa, D. E. y Devani, M. R. (2020). Uso de Teledetección y SIG para la detección de frecuencias de rotación soja/maíz en el departamento Burruyacu, provincia de Tucumán, Argentina. Revista Industrial y Agrícola de Tucumán, 96(1), 7-16.

Foody, G. M. (2002). Status of land cover classification accuracy assessment. Remote sensing of environment, 80(1), 185-201.

Gislason, P. O., Benediktsson, J. A., Sveinsson, J. R. (2006). Random forests for land cover classification. Pattern Recognition Letters, 27(4), 294-300.

Guerschman, J. P., Paruelo, J. M., Di Bella, C., M. Giallorenzi, C. y Pacin, F. (2003). Land cover classification in the Argentine Pampas using multi-temporal Landsat TM data. International Journal of Remote Sensing, 24(17), 3381-3402.

Guerschman, J.P. (2005). Análisis regional del impacto de los cambios del uso de la tierra sobre el funcionamiento de los ecosistemas de la región pampeana (Argentina). Tesis de Doctorado. Escuela para Graduados Alberto Soriano. Facultad de Agronomía. Universidad de Buenos Aires, Buenos Aires.

Hansen, M. C., Defries, R. S., Townshend, J. R. G. y Sohlberg, R. (2000). Global land cover classification at 1 km spatial resolution using a classification tree approach. International Journal of Remote Sensing, 21(6-7), 1331-1364.

Instituto Nacional de Estadísticas y Censos (INDEC). Censo Nacional Agropecuario. https://cna2018.indec.gob.ar/

Instituto Nacional de Tecnología Agropecuaria (2019). Mapa Nacional de Cultivos. Campaña 2018-2019. http://www.geointa.inta.gob.ar/2019/09/10/mapa-nacional-de-cultivos-campana-20182019/

Instituto Nacional de Tecnología Agropecuaria (2020). Mapa Nacional de Cultivos. Campaña 2019-2020. http://www.geointa.inta.gob.ar/2020/10/06/mapa-nacional-de-cultivos-campana-2019-2020/

Mc Guire, A. D., Sitch, S., Clein, J. S., Dargaville, R., Esser, G., Foley, Heimann, M., Joos, F., Kaplan, J., Kicklighter, D. W., Meier, R. A., Melillo, J. M., Moore, B., Prentice, I. C., Ramankutty, N., Reichenau, T., Schloss, A., Tian, H., Williams, L. J. y Wittenberg, U. (2001). Carbon balance of the terrestrial biosphere in the twentieth century: Analyses of CO2, climate and land use effects with four process-based ecosystem models. Global biogeochemical cycles, 15(1), 183-206.

Ministerio de Agricultura Ganadería y Pesca (MAGyP) (2015). Estimaciones Agrícolas. Distribución de la superficie agropecuaria según el uso actual de los suelos. https://www.magyp.gob.ar/sitio/areas/estimaciones/distribucion/cg2014-15/buenosaires/tandil.php.

Ministerio de Agricultura ganadería y Pesca (MAGyP). Estimaciones Agrícolas. Método de segmentos aleatorios. Metodología para la estimación de la superficie sembrada con cultivos extensivos. Versión V. https://www.magyp.gob.ar/sitio/areas/estimaciones/estimaciones/metodologia/_archivos//000000_Metodo%20de%20segmentos%20aleatorios%20(Version%205).pdf

Murthy, C. S., Raju, P. V. y 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 Sensing, 24 (23), 4871-4890.

Nolasco, M., Willington, E. A. y Bocco, M. (2014). Clasificación del uso de suelo en agricultura a partir de series temporales de imágenes Landsat. En VI Congreso Argentino de Agro Informática (pp. 64-73). Buenos Aires: Sociedad Argentina de Informática e Investigación Operativa (SADIO).

Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., y Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. Remote Sensing of Environment, 148, 42-57.

Pal, M. (2005). Random forest classifier for remote sensing classification. International Journal of Remote Sensing, 26(1), 217-222.

Paruelo, J. M. (2014). Clasificación de datos espectrales. En Percepción remota y sistemas de información geográfica. Sus aplicaciones en Agronomía y Ciencias Ambientales (pp161-185). Buenos Aires: Ediciones Hemisferio Sur.

Paruelo, J. M., Guerschman, J.P., Baldi, G., Di Bella, C. M. (2004). La estimación de la superficie agrícola. Antecedentes y una propuesta metodológica. Interciencia, 29 (8), 421-427.

Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., y Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS Journal of Photogrammetry and Remote Sensing, 67, 93-104.

Vazquez, P. S., Zulaica, M. L. y Requesens, E. (2016). Análisis ambiental de los cambios en el uso de las tierras en el partido de Azul. AgriScientia, 33 (1), 15-26.

Volante, J. N., Campos, C. J., Noé, Y. E.y Elena, H. J. (2007a). Método de Clasificación "Por-parcela" para la Detección de Cultivos: Aplicación al Área Agrícola de Las Lajitas (Salta, Argentina), Campaña Agrícola de Invierno 2006. En Proc. 12º

Congreso de la Asociación Española de Teledetección (pp. 79-86). Mar del Plata: Martín.

Volante, J. N., Paoli, H. P., Noé, Y. y Elena, H. J. (2007b). Análisis de la rotación de cultivos extensivos del noroeste argentino a partir de teledetección y sistemas de información geográfica. Período 2000-2005. En Proc. 12º Congreso de la Asociación Española de Teledetección. Mar del Plata: Martín.

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(3), 290-310.