

UNIVERSIDAD NACIONAL DE LA PLATA

FACULTAD DE CIENCIAS AGRARIAS Y FORESTALES



TRABAJO FINAL DE CARRERA

**“Teledetección aplicada al Agro. Clasificación de cultivos
a partir de imágenes satelitales”**

Modalidad: Investigación a dúo

Área temática: Teledetección aplicada al agro

Carrera: Ingeniería Agronómica.

Alumno: Barni, Matias Javier

Alumno: Ratto Elisa

Legajo: 27345/8

Legajo: 27020/8

D.N.I: 38.553.242

D.N.I: 37.012.861

E-mail: matias_barni@hotmail.com
/ barnimatias@gmail.com

E-mail: eli.ratto@hotmail.com

Teléfono:2227-553277

Teléfono: 2342-466228

Director: Ing. Ftal. Sebastián Ignacio Besteiro

Co-director: Ing. Agr. Hector Mariano Barragán Pera

Fecha: 21/06/2022

RESUMEN

El sector agrícola viene transitando un profundo cambio en la obtención y la utilización de nuevas tecnologías, buscando anticiparse a eventos edafoclimáticos que puedan inferir en los resultados productivos y facilitar la toma de decisiones de forma remota, empujando al profesional a un uso cada vez más extenso de herramientas tales como la teledetección y el manejo de información geoespacial en entornos GIS. La clasificación de imágenes provenientes de sensores remotos permite monitorear dichos cambios con precisión, en forma periódica y a menores costos que con los métodos tradicionales. Las imágenes de los satélites Landsat y Sentinel son ampliamente utilizadas para realizar clasificaciones de las coberturas del terreno, dado que presentan resoluciones espaciales convenientes, una cobertura espectral similar entre ellas y carecen de costos para su descarga y manipuleo.

En el presente trabajo se analizaron las ventajas y desventajas del uso de imágenes satelitales de mediana resolución (LANDSAT 8 OLI y Sentinel 2 MSI) al realizar clasificaciones supervisadas de los cultivos estivales existentes en una campaña agrícola en campos ubicados en el partido de Lobos, provincia de Buenos Aires. Para el logro del objetivo se trabajó sobre 8 imágenes (cuatro Landsat 8 y cuatro Sentinel 2) que abarcan el periodo de estudio desde Noviembre del 2019 hasta Abril del 2020, empleando diferentes métodos de clasificación supervisada del complemento Semiautomatic Classification Plugin (SCP) dentro del software Qgis.

El procedimiento ha requerido no solo de la obtención de las imágenes satelitales, su procesamiento y validación, sino también del relevamiento de datos de campo.

Se partió del supuesto que las clasificaciones derivadas del uso de ambas imágenes no presentan variaciones provocadas por la resolución espectral, pero sí frente a las diferencias en la resolución espacial, siendo las imágenes Landsat las que mejor representan la realidad de campo para el área de estudio.

Los resultados obtenidos no fueron congruentes con la hipótesis, ya que las imágenes que representaron mejor la realidad de campo corresponden a Sentinel 2.

INTRODUCCIÓN

Con el aumento de la población mundial y la creciente demanda de la producción agropecuaria existe la necesidad de una mejor administración de los recursos agrícolas del mundo. Para esto es necesario en primer lugar obtener datos fiables de tipo, calidad, cantidad y ubicación de estos recursos.

Por este motivo el sector agrícola viene transitando un profundo cambio en la obtención y la utilización de nuevas tecnologías, buscando anticiparse cada vez más a eventos edafoclimáticos que puedan inferir en los resultados productivos, y así facilitar la toma de decisiones incluso de forma remota, empujando al profesional al uso de la teledetección. La misma se define como la ciencia o el arte de adquirir información sobre un objeto, área o fenómeno a través de los datos adquiridos mediante un dispositivo que no está en contacto directo con el objeto, área o fenómeno bajo investigación (Chuvienco, 1995).

Podemos considerar a la teledetección como una herramienta de inventario, análisis, predicción y ayuda en la prevención agropecuaria. Todos ellos de gran relevancia político-económica.

Un instrumento importante dentro de la teledetección es el sistema de información geográfica (SIG) o Geographic information system (GIS), es un marco de trabajo para reunir, gestionar y analizar datos. Además, permite integrarlos, analizando la ubicación espacial y organizando capas de información para su visualización y posterior generación de mapas.

Las imágenes satelitales pueden ser utilizadas en diversas actividades para identificar coberturas presentes en la superficie terrestre, buscando clasificar agua, suelo desnudo, áreas edificadas, bosques, etc. Demostrando la necesidad de promover esta tecnología de forma que constituya un apoyo, reduciendo el tiempo invertido en la elaboración de investigaciones sobre la superficie terrestre.

Gracias a su formato digital es posible aplicar sobre ellas procedimientos matemáticos para la clasificación automática de grandes superficies.

La información provista por sensores remotos es importante para estudios relacionados con el uso y ocupación de la superficie del suelo; siendo la clasificación de imágenes uno de los problemas técnicos más importantes de la teledetección.

Entre las ventajas de estas respecto de otros métodos que obtienen datos a campo se encuentran un menor costo, cobertura de grandes áreas y la posibilidad de repetir la obtención de los datos a lo largo del tiempo (Pal & Mather, 2004).

El proceso de clasificación de imágenes permite la extracción de información contenida en ellas, complementando el análisis visual con la aplicación de técnicas cuantitativas para automatizar la identificación de los objetos contenidos en una escena. De esta manera, las imágenes son procesadas a través de algoritmos para asignar a cada unidad homogénea mínima (píxel) un tipo de cobertura de la tierra.

Por esta razón, resulta de gran importancia la utilización de la informática como herramienta para facilitar la incorporación de esta tecnología.

El uso de la teledetección como herramienta es muy amplia, un ejemplo de aplicación puede observarse en el trabajo de Caride y Paruelo donde mediante clasificaciones supervisadas con diferentes bandas, se estimó la superficie bajo siembra directa (SD) y labranza convencional (LC), en el norte de Buenos Aires. (Caride & Paruelo, 2007).

Objetivo General

Analizar las ventajas y desventajas del uso de imágenes satelitales de mediana resolución (LANDSAT 8 OLI y Sentinel 2 MSI) a partir de clasificaciones supervisadas de los cultivos estivales existentes en una campaña agrícola en campos ubicados en una zona del partido de Lobos, provincia de Buenos Aires.

Objetivos particulares

- 1- Comparar los resultados de las clasificaciones supervisadas entre Landsat 8 y Sentinel 2.
- 2- Determinación in-situ de los cultivos, coberturas y prácticas culturales a fin de determinar los polígonos de clasificación y control; las actividades productivas y culturales de la zona de estudio.
- 3- Desarrollar habilidades en el uso de herramientas SIG, de libre acceso tales como google earth y QGIS, ajustando las acciones de descarga, instalación y manejo de herramientas básicas para el procesado de imágenes descargadas.

4- Desarrollar habilidades de manejo de instrumental de campo tales como gps y su posterior procesamiento en gabinete.

Hipótesis

Se espera que las clasificaciones derivadas del uso de ambas fuentes de imágenes no presenten variaciones provocadas por la resolución espectral de estas, dada su semejanza, pero sí frente a las diferencias en la resolución espacial, siendo las imágenes Landsat las que mejor representen la realidad de campo para la porción del terreno analizado. Esto deriva de la menor resolución espacial de las imágenes Landsat 8 que podría evitar en gran medida el “grado de imprecisión” provocado por la incorporación de la variación intralote en el análisis de las coberturas y usos del suelo, permitiendo una clasificación de usos más fiel a la realidad.

MATERIALES Y MÉTODOS

En este trabajo se realizó una clasificación supervisada de cultivos de verano, maíz y soja. Esta clasificación se realizó en un entorno GIS, utilizando tanto softwares como imágenes satelitales de libre acceso. El procedimiento general requiere no solo el relevamiento de datos de campo, sino también de la obtención de las imágenes satelitales, su procesamiento y validación en un entorno GIS. El área de estudio está conformada por dos campos, ambos pertenecientes al partido de Lobos, Provincia de Buenos Aires, Argentina.

Dicha zona se caracteriza por presentar clima templado, temperatura media anual 16 °C y precipitación media anual de 959 mm.

Los suelos del área de estudio pertenecen a la Serie Udaondo (Ud), caracterizada por un suelo oscuro, profundo, con aptitud agrícola. Los mismos, se encuentran en una amplia llanura relativamente alta dentro de la Subregión Pampa Arenosa, transición a la Subregión Pampa Ondulada, con pendientes de 0,5 a 1%. Las actividades predominantes en la zona son:

- Ganadería, donde podemos observar establecimientos de cría, y en menor medida ciclo completo. Utilizando como principal recurso forrajero pastizal natural y en menor medida verdeos y pasturas.
- Agricultura, en suelos de aptitud agrícola, los cultivos más relevantes son maíz y soja en verano, mientras que en invierno principalmente lo es el trigo.
- También se observan establecimientos mixtos donde realizan rotaciones entre agricultura y pasturas para el ganado.

El área de estudio está conformada por dos campos que se encuentran distanciados entre sí por 1.300 metros (Figura 1). El primer campo se encuentra ubicado en las coordenadas 35°22'22"S 59°03'11"W, tiene 80 has y el cultivo analizado fue Soja. El cultivo antecesor en este lote fue maíz y se realizó un barbecho químico el 23/08/2019. La soja se sembró entre el 31/10/2019 y el 2/11/2019 a una distancia entre líneas de 0.35 metros y con una densidad de 80 kg/ha. Se sembraron 40 has con semilla DM4212 sts Don Mario y las otras 40 has con 4613 Nidera. El rendimiento promedio que se obtuvo fue de 4.000 kg/ha.

El segundo campo se encuentra en las coordenadas 35°23'41"S 59°02'44"W, tiene 21 has y el cultivo analizado fue maíz. El cultivo antecesor de este lote fue soja y se realizó un barbecho químico en julio/2019. El maíz se sembró entre el 22/10/2019 y el 24/10/2019 y se sembraron 55.000 plantas/ha. La variedad utilizada fue VTtriplepro de AGseed.

Relevamiento de datos a campo

Los cultivos estivales en estudio, corresponden a la campaña 2019/2020.

Se recopilaron 32 puntos en total a campo para georeferenciar los potreros cuyo detalle respecto a coberturas y el estado o condición de las mismas se enumeró en una planilla de campo. De los mismos, 16 pertenecen a los lotes y a su vez, se tomaron 12 puntos sobre los caminos para luego indicar en los campos linderos su cobertura. Del total de puntos se descartaron 9 por su proximidad dentro del lote. Posteriormente se descargaron del GPS a la aplicación BaseCamp, para luego ser utilizados en el SIG. (Figura 1).

Para Georeferenciar estos puntos se utilizó un gps garmin eTrex 10, usando la función waypoint, siendo almacenados en el dispositivo y además detallados en una planilla de campo.

En gabinete y con la utilización de la aplicación BaseCamp se crearon los polígonos que representan los potreros relevados, donde se adjunta la información recopilada en la planilla.

El software BaseCamp permite:

- Inspeccionar el terreno, muestra los datos de los mapas topográficos en 2D en la pantalla del ordenador.
- Geolocalizar fotos, asociándose con puntos de referencia específicos.
- Transferir imágenes por satélites.

En la figura 1 se representa el área de estudio, los lotes y puntos relevados, como también su ubicación en la Provincia de Buenos Aires.

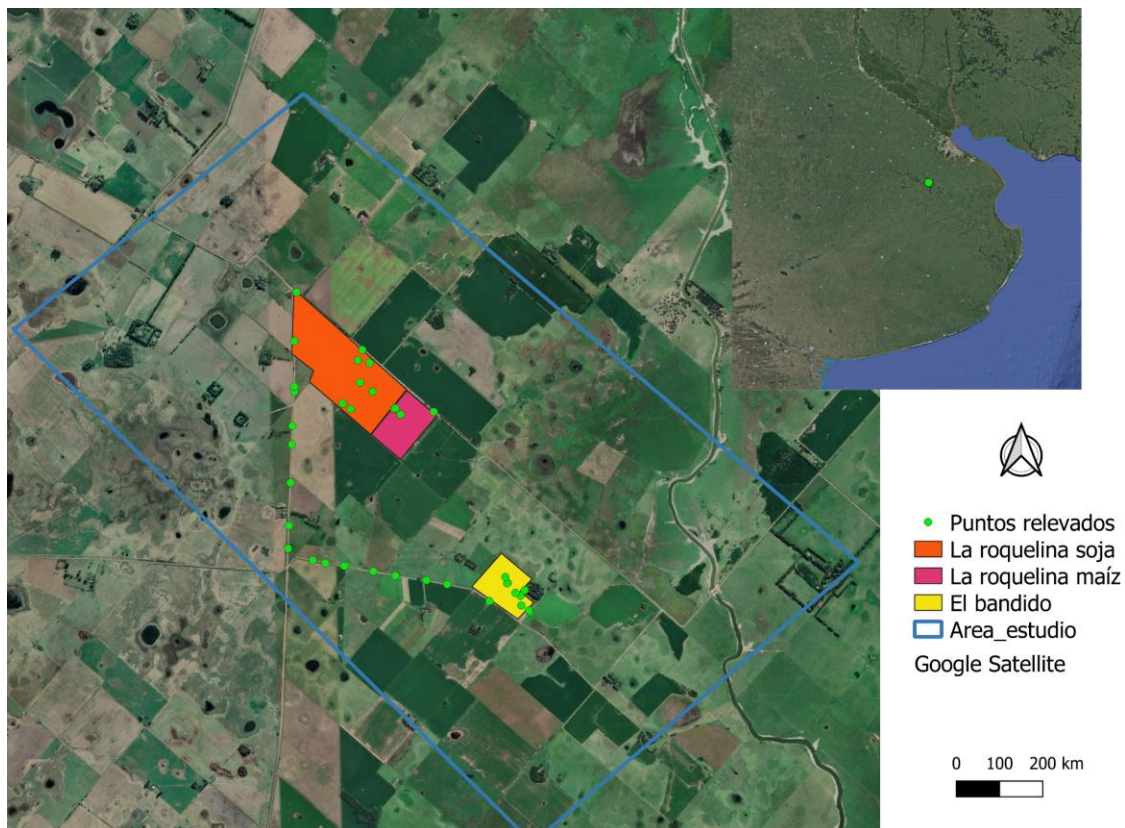


Figura 1. Ubicación de los campos en estudio y puntos relevados

Obtención de imágenes satelitales

Se utilizaron ocho imágenes satelitales de media resolución, en un periodo comprendido entre noviembre del 2019 a abril del 2020.

En la tabla N°1 se observan las fechas de las imágenes utilizadas.

Tabla 1. Fecha de descarga de imágenes satelitales

Satélite	Fecha
Landsat 8	15/11/2019
	17/12/2019
	19/02/2020
	07/04/2020
Sentinel 2	10/11/2019
	10/12/2019
	28/02/2020
	08/04/2020

Las cuatro imágenes correspondientes a LANDSAT 8 se obtuvieron de la página web USGS (Servicio Geológico de Estados Unidos) y las cuatro imágenes SENTINEL 2, de la página web Copernicus, ambas sin corrección atmosférica.

Para descargar las imágenes de forma gratuita de las páginas web, es necesario en primera instancia loguearse, lo cual implica el registro como nuevo usuario que habitualmente se hace en las páginas que así lo requieren. Una vez registrados, se delimita la zona a analizar mediante el trazado de un polígono rectangular, definido por sus extremos, y se indica el intervalo de tiempo deseado, entre otros parámetros tales como la nubosidad.

Debido a que la resolución temporal o período de revisita del satélite LANDSAT 8 es de 16 días, mientras que el SENTINEL 2 es de 5, se buscó que las fechas de ambos sean lo más cercanas posibles, descartando aquellas que no se encontrarán pareadas temporalmente y así minimizar variaciones.

Para el periodo comprendido a analizar, las páginas de descarga antes mencionadas ofrecen varias imágenes de la zona de estudio, pero se procedió a elegir las que presenten una mejor visualización y donde se permita diferenciar los estadios de los cultivos, descartando las imágenes con alta cobertura de nubes.

Procesamiento

El proyecto se llevó a cabo trabajando en un entorno GIS, mediante la utilización del Software Quantum GIS (Qgis) en su versión 3.10.13 para procesar información geográfica e imágenes satelitales.

En la etapa de procesamiento de las imágenes se utilizó el complemento Semiautomatic Classification Plugin (SCP); que entre varias de sus utilidades permite:

- Combinar las bandas de la imagen, analizando elementos específicos de la superficie terrestre en función de su espectro de emisión.
- Elegir los distintos criterios de clasificación supervisada (algoritmos que agrupan los píxeles según máxima probabilidad, distancia mínima, etc.).

Para realizar la clasificación supervisada de las imágenes de ambos satélites se eligieron como criterios de clasificación al Mapeo de ángulo espectral y distancia mínima.

Mediante la clasificación se obtiene una cartografía e inventario de las categorías de interés. En el proceso, una imagen multibanda se convierte en otra, ahora de una sola banda, donde cada ND representa la etiqueta que identifica la categoría temática asignada a ese píxel.

Para la clasificación se definieron macro clases y clases, que se corresponden con la cantidad de polígonos tomados como áreas de entrenamiento en cada macroclase.

La clasificación de imágenes satelitales se ve afectada por la resolución espacial y espectral y puede realizarse a través de clasificadores por píxeles o por regiones. Los primeros consideran la reflectancia de cada píxel para asignarlo a una clase, mientras que los segundos consideran la vecindad del píxel mediante un proceso de agrupación de píxeles vecinos en regiones homogéneas, previo a la clasificación (Conde, Perelman & Cerezo, 2009).

Las actividades anteriormente mencionadas se realizaron en conjunto durante las visitas requeridas, mientras que el trabajo de gabinete fue distribuido entre ambos participantes. La tesista Elisa Ratto realizó el procesamiento de imágenes LANDSAT 8, su posterior clasificación supervisada y validación. Mientras que el tesista Matias Barni, procedió de la misma manera con las imágenes SENTINEL 2.

El procedimiento metodológico fue adaptado de la experiencia adquirida en cursos realizados en el ámbito de nuestra formación de grado a lo largo del desarrollo de la presente tesis (Sensores Remotos, UNLP).

Para analizar las imágenes se armaron stacks con las bandas de interés, el stack es un apilado de las mismas. Para el Landsat 8 se utilizaron las bandas: 2 (azul), 3 (verde), 4 (rojo) y 5 (NIR). Y para el Sentinel 2 las bandas 2 (azul), 3 (verde), 4 (rojo) y 8a (rojo cercano, NIR 1). No se incluyeron todas las bandas de la imagen, ya que algunas de ellas no son de utilidad para nuestro estudio. Las bandas utilizadas en ambos satélites corresponden al mismo rango espectral.

Se realizaron stacks para cada una de las imágenes descargadas, mediante el programa Qgis, en herramientas: raster, miscelanea y combinar bandas.

A su vez, se realizó un stack multitemporal para cada satélite, donde se apilaron todas las bandas utilizadas de las 4 imágenes descargadas.

Para el análisis visual, se optó por una de las combinaciones más utilizadas en agricultura, 5-4-3 (Landsat 8) y 8a-4-3 (Sentinel 2), que incluyen las bandas del Infrarrojo cercano y medio y la banda visible roja (Banda 4 en ambos satélites).

Esto permite apreciar mejor la vegetación, mejorando el contraste de los cultivos analizados y el pastizal natural con el suelo desnudo, debido a que la clorofila en una planta sana absorbe la mayor parte de la luz roja, mientras que la estructura celular refleja la mayor parte de la luz infrarroja.

La creación de estas imágenes parte del paso de bandas a través de tres canales (RGB): rojo, verde y azul. El paso de cada banda por un canal u otro permitirá teñir de colores los elementos que ofrezcan mayor o menor reflexión de longitudes de onda; y dará como resultado, la combinación de estas para formar una imagen a color natural o a falso color, realzando elementos muy concretos para su posterior estudio y análisis.

Landsat 8 y Sentinel 2 presentan diversas bandas que operan bajo rangos parecidos, lo que implica en algunas situaciones, la necesidad de combinarlas de manera distinta en función del estudio deseado. (Figura 2)

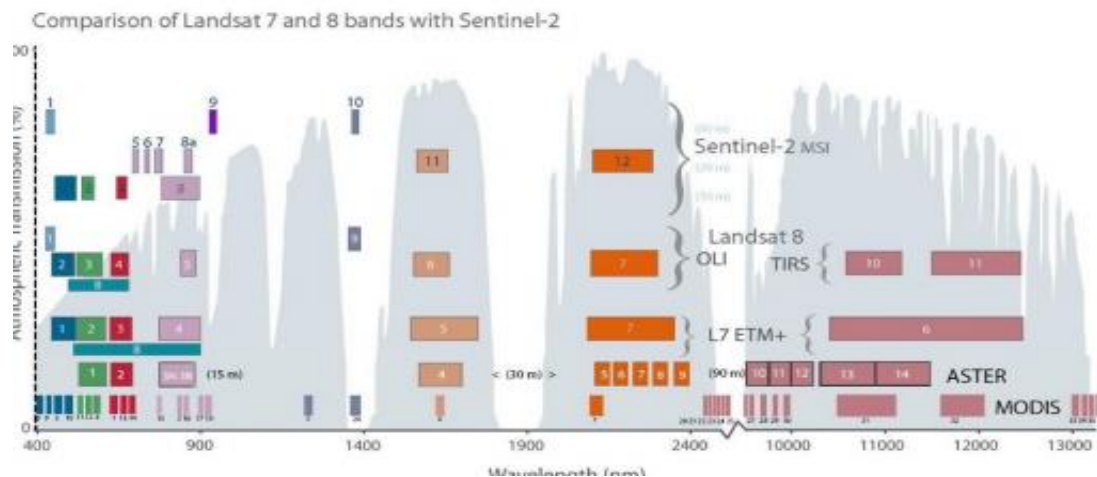


Figura 2. Comparación de distintos satélites en cuanto a su resolución espectral y espacial. Fuente: USGS.

El trabajo se proyectó en SRC: EPSG: 5347 - POSGAR 2007 / Argentina 5, que se corresponde con la franja que atraviesa la zona de estudio.

POSGAR 07 (Posiciones Geodésicas Argentinas 2007) fue adoptado por el Instituto Geográfico Nacional (IGN) como el Marco de Referencia Geodésico Nacional a través de la Disposición N° 20/2009 del 15 de mayo de 2009, reemplazando al hasta entonces vigente POSGAR 94.

Resumiendo, las etapas de la clasificación son:

Etapas de entrenamiento: en esta etapa se definen numéricamente las categorías. Se procede a entrenar el programa para que, mediante los puntos relevados a campo, se asignen ciertas categorías que va a representar una cobertura dada y el programa las reconozca como tal.

En esta etapa se generó un archivo donde se utilizaron el 50% de los puntos relevados a campo para crear la muestra de entrenamiento. Luego se realizó un buffer alrededor de cada punto para que se transforme en un polígono de muestra que representa el tamaño del objeto mínimo mapeable, en nuestro caso se llevó a 1 hectárea. Y se entrenó al programa asignando a cada polígono la categoría que correspondía.

Etapas de asignación: en esta etapa se categorizan los píxeles de la imagen. El programa reconoce cada píxel en una categoría debido al entrenamiento y por lo tanto, asigna y categoriza todos los píxeles de la imagen.

Validación de los resultados: Luego de realizar la clasificación, evaluamos la exactitud del resultado obtenido a fin de identificar y medir los errores. Esta evaluación se realizó a través del cálculo de una matriz de errores o matriz de confusión, que compara la información del mapa resultante de la clasificación con un conjunto de datos de referencia o puntos de control tomados a campo. Los valores de la matriz expresan el número de píxeles asignados a una categoría en particular, en relación con la verdadera categoría verificada con la información de referencia. La validación de la clasificación nos permite hacer una evaluación realista de los errores siempre que la muestra de píxeles para la estimación del error sea lo suficientemente representativa.

En esta etapa se utilizaron el 50% restante de los puntos relevados a campo, para generar la muestra control. Luego se realizó un buffer alrededor de cada punto para que se transforme en un polígono de muestra que representa el tamaño del objeto mínimo mapeable, en nuestro caso se llevó a 1 hectárea. Posteriormente se asignó a cada muestra la cobertura que representa para poder cruzarla con la clasificación.

Los índices utilizados para evaluar la eficiencia de la validación son:

1. Índice Kappa: calcula la correspondencia entre la imagen clasificada y la realidad de acuerdo a la exactitud de la clasificación y eliminando la componente del azar.

Es una medida de la diferencia entre la exactitud lograda en la clasificación con un clasificador automático y la aleatoriedad de lograr una clasificación correcta con un clasificador cualquiera que pueda conducir a resultados aparentemente correctos en la matriz de confusión.

El valor de K varía entre -1 y 1, y se calcula como:

$$k = \frac{[(\sum \text{concordancias observadas}) - (\sum \text{concordancias atribuibles al azar})]}{[(\text{Total de observaciones}) - (\sum \text{concordancias atribuibles al azar})]}$$

Existen rangos propuestos para valorar el grado de acuerdo en función del índice kappa. (Tabla 2).

Tabla 2. Valoración del coeficiente Kappa. Adaptado de Landis y Koch (1977).

Coeficiente Kappa	Fuerza de concordancia
0,00	Pobre
0,01 - 0,20	Leve
0,21 - 0,40	Aceptable
0,41 - 0,60	Moderada
0,61 - 0,80	Considerable
0,81 - 1,00	Casi perfecta

2. Precisión global: cuantifica el número de píxeles clasificados correctamente. Se calcula dividiendo el número total de píxeles correctamente clasificados por el número total de píxeles de referencia y expresándose como porcentaje.

$$PG = \sum ii/N$$

Para realizar la validación de las clasificaciones y generar las matrices de confusión, se utilizó como herramienta del Qgis, al Semiautomatic Classification Plugin (SCP).

Una vez obtenidas las muestras control, se pudo comparar con la clasificación y así evaluar el grado de coincidencia. Para esto se utilizó el SCP, dirigiéndonos a la función postprocesamiento, para luego ingresar en precisión. Aquí el programa realizó el cruce entre la clasificación realizada y las muestras control arrojando una matriz de confusión para analizar posteriormente sus resultados.

En la matriz de confusión se puede observar y analizar lo siguiente:

- Cada fila representa lo observado en la clasificación.
- Cada columna representa lo observado en la muestra control.
- En los cruces de la matriz de confusión, cada valor es el porcentaje en función al total de píxeles.
- El total de cada columna representa el total muestreado en las muestras control por categoría.

- El total de las filas representa el total en área (m^2) de cada categoría en la clasificación y el W_i es la relación en función al área total (en las muestras).

RESULTADOS

A continuación se presentan los resultados de las clasificaciones supervisadas del Stack, que contiene todas las fechas analizadas, para ambas fuentes de imágenes y criterios de clasificación (Figura 3). Luego se analiza cada imagen por separado. (Figuras 4 a 7).

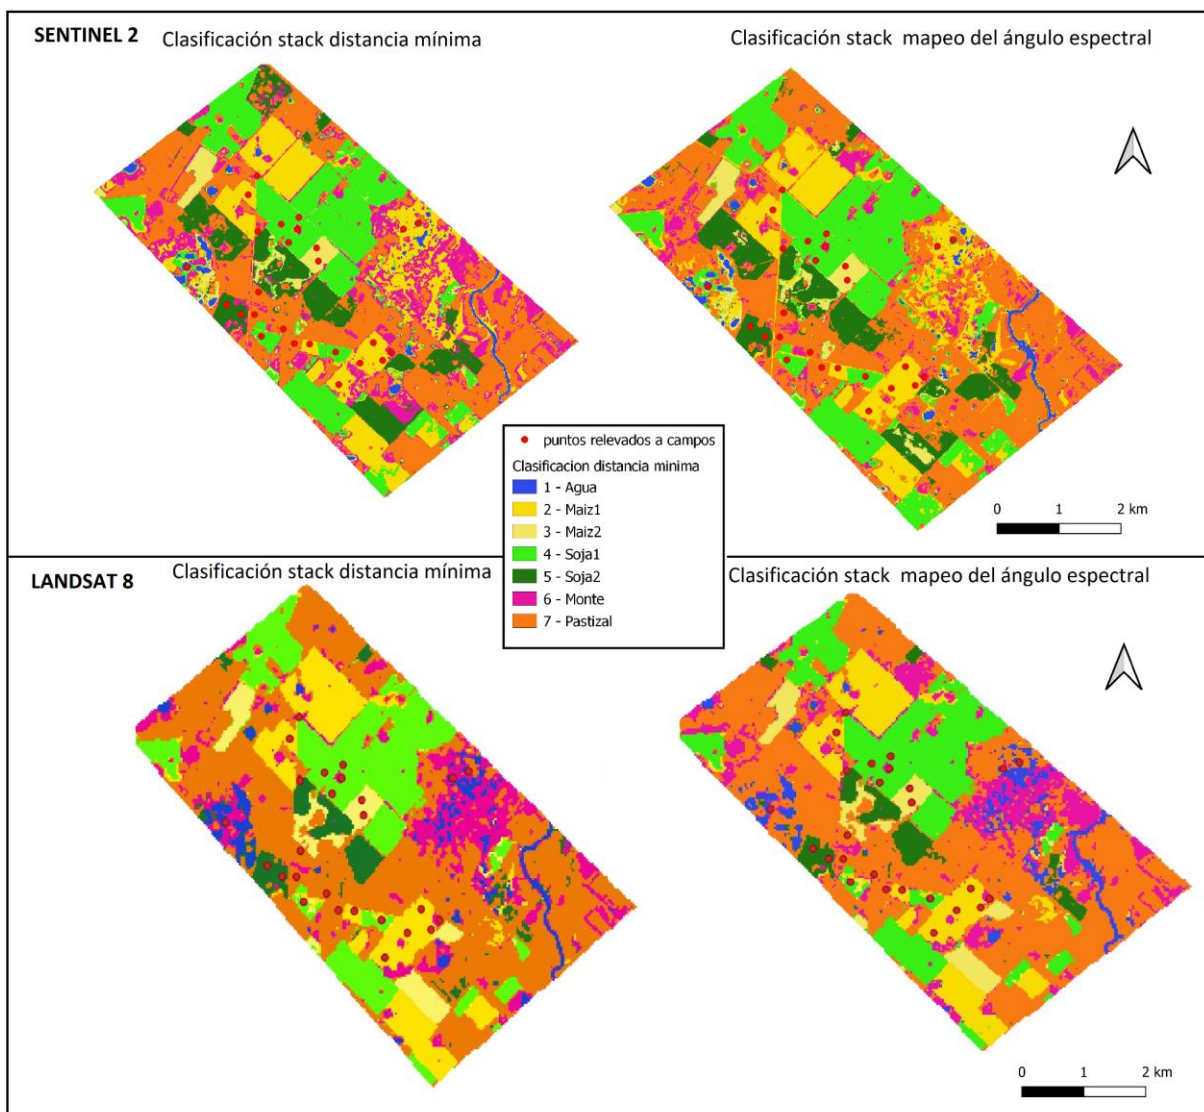


Figura 3. Clasificaciones supervisadas de ambas fuentes de imágenes.

Sentinel 2:

Stack:

Distancia mínima

Se observa la imagen clasificada del stack y a continuación la matriz correspondiente

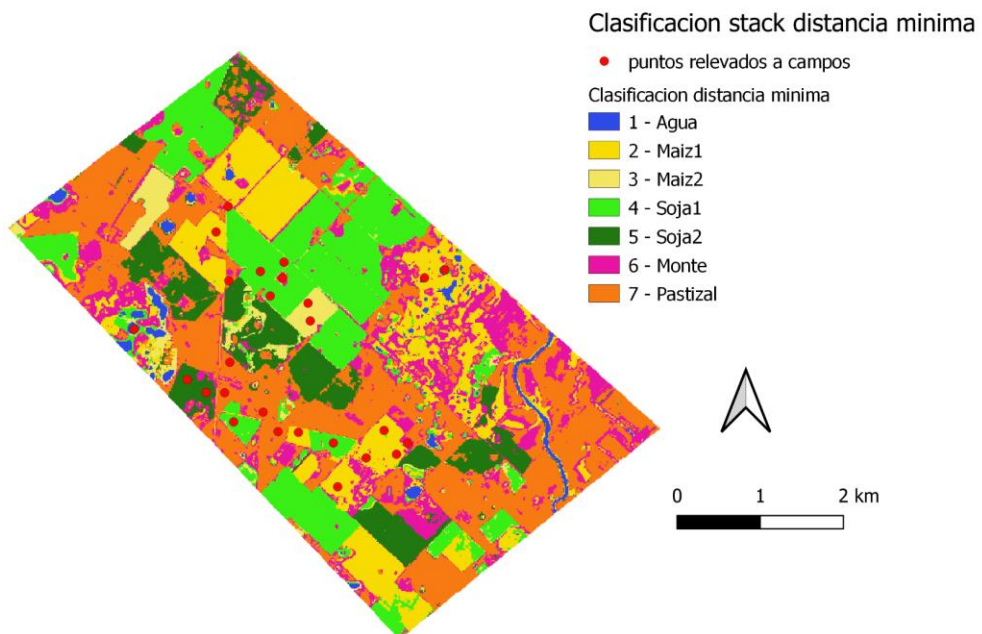


Figura 4. Clasificación Stack por distancia mínima Sentinel 2.

Tabla 3. Matriz de confusión, stack distancia mínima.

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2da	Monte	Pastizal		
No dato									33.323.484	57%
Agua		1%	0%	0%	0%	0%	0%	0%	426.451	1%
Maiz 1ra		0%	6%	0%	0%	0%	0%	0%	4.245.908	7%
Maiz 2da		0%	0%	2%	0%	0%	0%	0%	935.512	2%
Soja 1ra		0%	0%	0%	8%	0%	0%	0%	5.136.314	9%
Soja 2da		0%	0%	0%	0%	4%	0%	0%	2.665.119	5%
Monte		0%	0%	0%	0%	0%	6%	0%	3.984.276	7%
Pastizal		0%	0%	0%	0%	0%	1%	13%	8.006.357	14%
Total		1%	7%	2%	8%	5%	8%	13%	58.723.420	
Area (m2)	0	752.687	4.017.820	926.014	4.983.077	2.649.567	4.442.770	7.628.001	58.723.420	

Precisión total [%] =40,1932
 Clasf. Kappa [Adim.] =0,3786

En la matriz (Tabla 3) se observa que tanto en soja de primera como en pastizal hay una sobreestimación de la superficie, debido a que la superficie clasificada en ambos casos es mayor a la superficie control, mientras que para la macroclase monte, hay una subestimación de la superficie, la misma en la muestra control es superior a la correspondiente clasificada.

Mapeo ángulo espectral

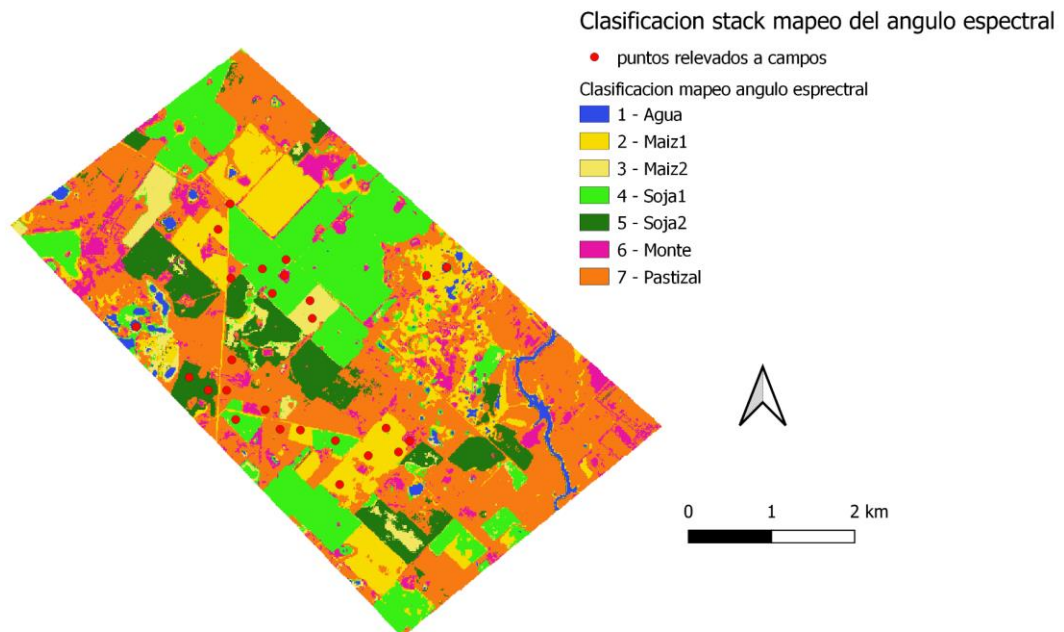


Figura 5. Clasificación Stack por mapeo del ángulo espectral Sentinel 2.

Tabla 4. Matriz de confusión, stack mapeo del ángulo espectral.

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2da	Monte	Pastizal		
No dato									33.323.484	57%
Agua		1%	0%	0%	0%	0%	0%	0%	477.757	1%
Maiz 1ra		0%	6%	0%	0%	0%	0%	0%	3.902.367	7%
Maiz 2da		0%	0%	2%	0%	0%	0%	0%	1.042.125	2%
Soja 1ra		0%	0%	0%	9%	0%	0%	0%	5.399.946	9%
Soja 2da		0%	0%	0%	0%	4%	0%	0%	2.539.704	4%
Monte		0%	0%	0%	0%	0%	3%	0%	1.803.816	3%
Pastizal		0%	0%	0%	0%	0%	2%	15%	10.234.223	17%
Total		1%	6%	2%	9%	4%	6%	15%	58.723.420	
Area (m2)	0	795.200	3.492.125	1.006.011	5.202.074	2.477.456	3.361.922	9.065.148	58.723.420	

Precisión total [%] =39,5771
 Clasf. Kappa [Adim.] =0,3686

Se observa en la matriz (tabla 4), que para la clase monte hay una subestimación, debido a que la superficie total control es mayor a la superficie total clasificada, mientras que para las macroclase maíz de primera y pastizal, hay una sobreestimación, se puede ver que en ambos casos la superficie clasificada es mayor a la superficie control.

Landsat 8a

Stack

Distancia mínima

Se observa la imagen resultante de la clasificación del Stack y a continuación la matriz correspondiente.

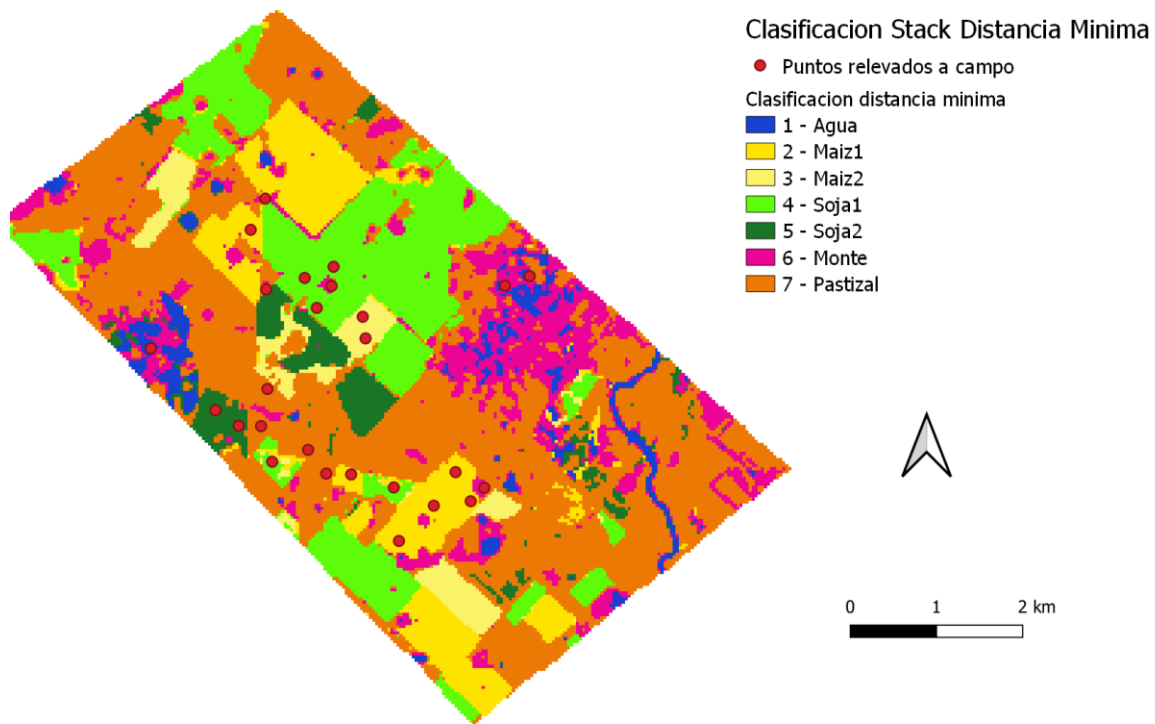


Figura 6. Clasificación Stack Distancia Mínima

Tabla 5. Matriz de confusión Stack Distancia mínima

Clasificación	Referencia								Area (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Soja 1	Soja 2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		2%	0%	0%	0%	0%	0%	0%	978.417	2%
Maiz 1		0%	4%	0%	0%	0%	0%	0%	2.920.849	5%
Maiz 2		0%	0%	2%	0%	0%	0%	0%	1.106.232	2%
Soja 1		0%	0%	0%	7%	0%	1%	0%	4.573.446	8%
Soja 2		0%	0%	0%	0%	2%	0%	0%	1.181.841	2%
Monte		1%	0%	0%	0%	0%	4%	0%	3.116.172	5%
Pastizal		1%	0%	0%	0%	0%	1%	18%	11.519.576	19%
Total		4%	4%	2%	7%	2%	6%	18%	59.493.509	
Area		2.148.584	2.596.310	1.058.135	4.423.201	1.027.688	3.576.538	10.566.078	59.493.508	

Precisión total [%] =38,0442
 Clasf. Kappa [Adim]=0,3501

En la matriz (tabla 5) observamos que el total de la referencia en agua es 4% y el total de la clasificación agua es 2%. Esto significa que el agua fue subestimada en la clasificación. Lo mismo sucede con el monte.

En maíz 1ra, soja primera y pastizal ocurre lo contrario, en la clasificación se encontró más área que en el control, por lo tanto, la clasificación sobreestimó dichas coberturas

Mapeo ángulo espectral

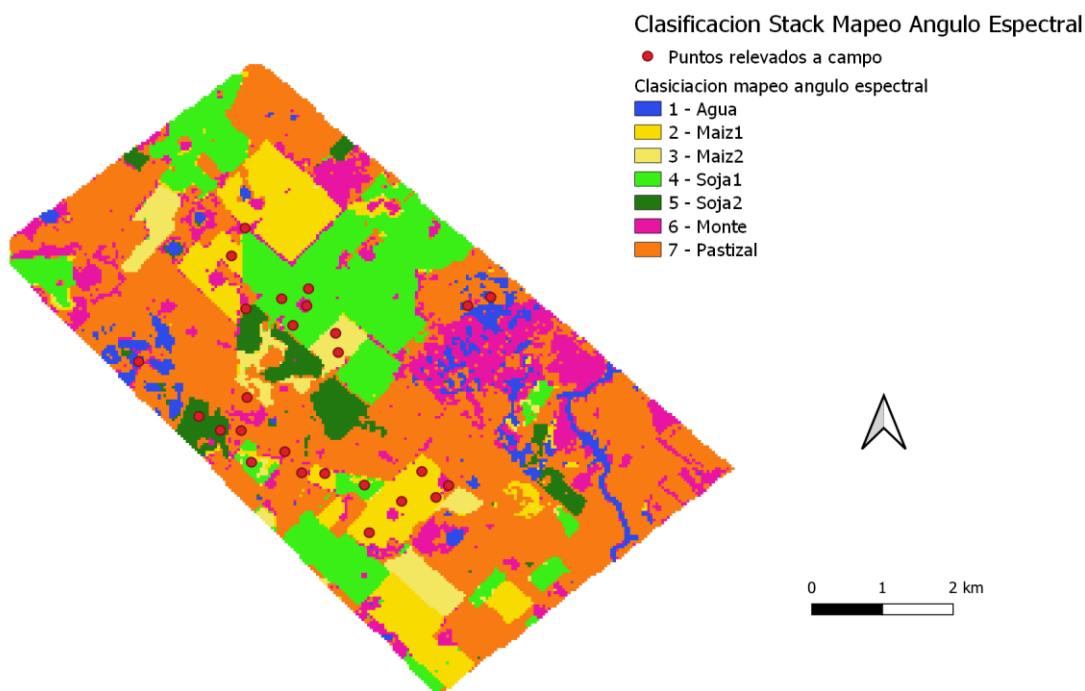


Figura 7. Clasificación Stack Mapeo Ángulo Espectral

Tabla 6. Matriz de confusión Stack Mapeo Ángulo Espectral

Clasificación	Referencia								Área (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Soja 1	Soja 2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		2%	0%	0%	0%	0%	0%	0%	1.083.729	2%
Maiz 1		0%	5%	0%	0%	0%	0%	0%	2.896.546	5%
Maiz 2		0%	0%	2%	0%	0%	0%	0%	1.133.235	2%
Soja 1		0%	0%	0%	7%	0%	1%	0%	4.557.245	8%
Soja 2		0%	0%	0%	0%	2%	0%	0%	1.096.331	2%
Monte		0%	0%	0%	0%	0%	6%	0%	3.271.891	6%
Pastizal		4%	0%	0%	0%	0%	1%	14%	11.357.557	19%
Total		6%	5%	2%	7%	2%	7%	15%	59.493.509	
Área	0	3.281.966	2.726.161	1.038.799	4.350.666	953.331	4.292.850	8.752.761	59.493.508	

Precisión total [%] =36,7346
 Clasf. Kappa [Adim] =0,3399

En la Matriz (tabla 6) observamos que el total de la referencia en agua es 6% y el total de la clasificación agua es 2%. Esto significa que el agua fue subestimada en la clasificación. Lo mismo sucede con el monte.

En soja 1ra y pastizal ocurre lo contrario, en la clasificación se encontró más área que en el control, por lo tanto, la clasificación sobreestimó dichas coberturas.

Anteriormente se visualizan las imágenes y validaciones del Stack. Realizando la validación de todas las imágenes analizadas, pudimos hacer una evaluación de los errores, a través del cálculo de una matriz de confusión, comparando la información del mapa resultante de la clasificación con un conjunto de datos de referencia o puntos de control tomados a campo.

Luego de realizar la misma obtuvimos los resultados expresados en las tablas N°7, (Resultados de los índices analizados en las clasificaciones de Sentinel 2) y N°8 (Resultados de los índices analizados en las clasificaciones de Landsat 8).

Tabla 7. Resultados de los índices obtenidos para distintos criterios de clasificación del SCP con imágenes Sentinel 2

		Sentinel 2			
Mes		Mapeo ángulo espectral	Distancia mínima	Dif Precisión	Dif. Índice de Kappa
Noviembre	Precisión %	35,4265	38,3305	2,904	
	Índice de Kappa	0,32	0,3527		0,0327
Diciembre	Precisión %	33,699	37,4654	3,7664	
	Índice de Kappa	0,315	0,347		0,032

Febrero	Precisión %	31,6585	31,7631	0,1046	
	Índice de Kappa	0,2901	0,2895		-0,0006
Abril	Precisión %	33,7265	34,3524	0,6259	
	Índice de Kappa	0,3126	0,3222		0,0096
Stack	Precisión %	39,5771	40,1932	0,6161	
	Índice de Kappa	0,3686	0,3786		0,01
			Promedio	1,6034	0,01674

Tabla 8. Resultados de los índices obtenidos para distintos criterios de clasificación del SCP con imágenes Landsat 8

		Landsat 8			
Mes		<i>Mapeo ángulo espectral</i>	<i>Distancia mínima</i>	Dif Precisión	Dif. Índice de Kappa
Noviembre	Precisión %	34,9	35,0939	0,1939	
	Índice de Kappa	0,3194	0,323		0,0036
Diciembre	Precisión %	31,766	35,0806	3,3146	
	Índice de Kappa	0,302	0,325		0,023

Febrero	Precisión %	33,7262	33,7684	0,0422	
	Índice de Kappa	0,3143	0,3136		-0,0007
Abril	Precisión %	27,735	30,4627	2,7277	
	Índice de Kappa	0,2544	0,279		0,0246
Stack	Precisión %	36,7346	38,0442	1,3096	
	Índice de Kappa	0,3399	0,3501		0,0102
			Promedio	1,5176	0,01214

Las tablas N° 7 y N° 8 resumen los resultados de las matrices de confusión obtenidas al realizar la validación de las clasificaciones. En ambos satélites se observa que para la imagen clasificada de cada mes el índice de Kappa y el de precisión fueron superiores para el procesamiento por distancia mínima.

DISCUSIÓN

En función de los resultados obtenidos se realizó una valoración visual y otra analítica. En la (tabla 9) se presenta una comparativa de los índices obtenidos para cada situación.

Tabla 9. Diferencia de precisión e índice Kappa entre Sentinel 2 y Landsat 8

Promedio	Sentinel 2	Landsat 8	Dif Sentinel 2/Landsat 8
Precisión %	1,6034	1,5176	0,0858
Índice de kappa	0,01674	0,01214	0,0046

Los valores obtenidos (Tablas 7 a 9) muestran que tanto en Sentinel 2 como Landsat 8, la clasificación por distancia mínima tiene una precisión mayor al mapeo del ángulo espectral en 0,0858%.

Los resultados obtenidos confirman lo expuesto por Chuvieco, E. (1995) al indicar que la diferencia entre los dos métodos de clasificación, analizados en la tabla 7 y 8, se debe al criterio de asignación de los píxeles, para el caso de distancia

mínima consiste en incluirlo en una de las categorías más cercana, en aquella que minimice la distancia entre ese píxel y el centroide de clase. En cambio, en el caso del mapeo de ángulo espectral, se calcula el ángulo espectral entre las firmas de los píxeles de la imagen y las firmas de entrenamiento (semiautomatic classification manual). Según estos criterios de asignación de píxeles, al hacer una comparación visual de los métodos de clasificación, se observan pequeñas variaciones en las clases monte y pastizal (Figuras 4 a 7). Esto mismo se observa reflejado también en el índice de Kappa (Tablas 7 a 9).

La imagen correspondiente al stack multitemporal es la que tuvo la mayor precisión e índice de Kappa. Los mejores resultados obtenidos en el stack se debe a que al tener mayor información cada píxel, ya que se encuentran agrupadas las 4 imágenes correspondientes a los meses analizados, tiene mayor cantidad de datos para procesar y así poder clasificar con mayor precisión.

Generalmente para la zona analizada se esperan valores de precisión cercanos al 80 %, en clasificaciones supervisadas. En nuestro caso esos valores están por debajo, esto pudo deberse a una incorrecta elección de clases o que a la hora de realizar el entrenamiento, el número de polígonos tomado fue insuficientes dentro de una clase, lo cual influye en el ruido intralote y por lo tanto en el resultado final.

En las matrices se observa una superficie amplia para el no data, representando un valor superior al 50% de esta, dicha superficie no tiene incidencia alguna en los resultados finales ya que no fue contemplada en la clasificación.

CONCLUSIONES Y RECOMENDACIONES

Al analizar los resultados, podemos concluir que las imágenes obtenidas de Sentinel 2 poseen mejores índices globales que las provenientes de Landsat 8 debido a que esta última posee una menor resolución espacial. En cuanto a la clasificación, el método por distancia mínima brinda una mayor precisión con respecto al ángulo espectral, pero esto es cierto en parte, ya que este método no deja píxeles sin clasificar sobrevalorando la precisión y el índice de Kappa.

Se observó también que las imágenes multitemporales destacaron positivamente en los índices globales ya que cuentan con una mayor cantidad de datos a procesar.

Coincidimos en que una mejora en los índices es posible realizando una toma de polígonos con mayor detalle buscando similitudes entre píxeles para cada clase o un filtrado previo a la validación que elimina el ruido intralote. Se podría utilizar un filtrado de paso bajo que asemeja el ND de cada píxel al de los vecinos; o un filtro de paso alto que resalta los contrastes espaciales entre píxeles vecinos.

En caso de no realizar un filtrado como se mencionó en el párrafo anterior, recomendamos utilizar imágenes provenientes de sentinel 2, ya que tienen ventajas respecto a las imágenes Landsat 8, brindan una mayor resolución espacial y cuenta con un periodo de revisita más corto, teniendo una mayor cantidad de imágenes disponibles en un mismo periodo de tiempo.

Cabe mencionar que para el periodo evaluado no fue posible utilizar Landsat 9, ya que fue puesto en órbita el 27 de septiembre de 2021 y sus imágenes estuvieron disponibles recién para febrero del 2022. Landsat 9 realiza un barrido completo del planeta en un período de 16 días, pero con un desfase en el recorrido con respecto a Landsat 8 de 8 días, de modo que en conjunto ofrecen imágenes de todo el planeta con un período de revisita de 8 días.

Destacamos que dichas imágenes se pueden obtener de una plataforma gratuita y de libre acceso, estando al alcance tanto de estudiantes como profesionales.

Este trabajo nos permitió adquirir experiencia para nuestras prácticas profesionales en el uso de herramientas SIG y en la utilización de instrumentos de campo como el GPS. En la práctica, Qgis nos permite ahorrar tiempo y superficie a analizar. Ya que relevando puntos a campo, posibilita extrapolar datos a una superficie mayor. Además es un instrumento que permite repetir la obtención de datos a lo largo del tiempo, sin necesidad de una revisita.

Aunque estas herramientas nos permiten trabajar de manera remota, es importante el conocimiento del terreno para ponderar la precisión de la clasificación o el grado de imprecisión del mismo, por lo que se debe realizar relevamiento de cobertura, estado de la misma, condiciones del sitio y cualquier factor que pueda generar confusión al momento del análisis.

BIBLIOGRAFÍA

- **Caride, C., & Paruelo, J. M.** 2007. Discriminación del sistema de labranza mediante el uso de imágenes Landsat en el Norte de Buenos Aires. *TELEDETECCIÓN-Hacia un mejor entendimiento de la dinámica global y regional*. Ed. Martin. [1]
- **Chuvienco, E.** 1995, FUNDAMENTOS DE LA TELEDETECCIÓN, segunda edición. Editorial: Rial S.A, Madrid, España.
- **Combinaciones RGB de imágenes satélite Landsat y Sentinel.** 2017. Disponible en: <http://www.gisandbeers.com/combinacion-de-imagenes-satelite-landsat-sentinel-rgb> (último acceso 26/03/2021).
- **Conde, M.C., Perelman, S.B. y Cerezo, A.** 2004. Efecto de diferentes métodos de clasificación de imágenes satelitales sobre índices de paisaje. Departamento de Métodos cuantitativos y sistema de información. Facultad de Agronomía-UBA, Ciudad de Buenos Aires, 2009.
- Curso de Grado “Sensores Remotos”, Facultad de Ciencias Naturales y Museo, UNLP.
- **Datos demográficos de nuestra ciudad.** Disponible en: <https://www.lobos.gob.ar/?q=datos-demograficos-nuestra-ciudad> (último acceso 26/03/2021).
- **El satélite Landsat 8: imagenes, descripcion y características.** Disponible en: <https://eos.com/es/landsat-8/> (último acceso 26/03/2021).
- **Imágenes Satelitales para la agricultura, Satellite Imaging Corporation.** Disponible en: https://www.satimagingcorp.com/applications/natural-resources/agriculture/agricultura_es/ (último acceso 20/05/2021).
- **Instituto Geografico Nacional (IGN)** . Disponible en: <https://www.ign.gob.ar/NuestrasActividades/Geodesia/Introduccion> (último acceso 30/08/2021).
- **INTA.** 1976. CARTA DE SUELOS DE LA REPÚBLICA ARGENTINA. Disponible en: <http://anterior.inta.gov.ar/suelos/cartas/series/Udaondo.htm> (último acceso 26/03/2021).
- **J. Serrano, J. Fabrega, E. Quiros, J. Sanchez-Galan y J. Jimenez.** 2018. “Análisis Prospectivo de la Detección Hiperespectral de Cultivos de Arroz (Oryza Sativa L.)”, KnE Engineering, vol. 3, no. 1, p. 69, 2018. Disponible en: <https://ridda2.utp.ac.pa/bitstream/handle/123456789/9432/clei-2019->

- [clasificacion-supervizada.pdf?sequence=1&isAllowed=y](#) (Último acceso 13/02/2022)
- **José M. Massa, María José Álvarez, Paula Tristán, Rubén Wainschenker.** CACIC 2011. Clasificación Automática de Cubiertas Terrestres en Imágenes Satelitales. Disponible en:
http://sedici.unlp.edu.ar/bitstream/handle/10915/18694/Documento_completo.pdf?sequence=1&isAllowed=y (último acceso 28/05/2021).
 - **Landis J, Koch G:** 1977. The measurement of observer agreement for categorical data. Biometrics 1977; 33: 159-74. (tabla coeficiente de kappa)
 - **Landsat 9: Un nuevo satélite con información abierta:**
<https://www.idecor.gob.ar/landsat-9-un-nuevo-satelite-con-informacion-abierta/>
(ultimo acceso 19/08/2022)
 - **Lucas Congedo.** 2012-2017. Breve introducción a la teledetección. Disponible en: https://semiautomaticclassificationmanual-v5.readthedocs.io/es/latest/remote_sensing.html (Ultimo acceso 13/02/2022).
 - **Pal, M., Mather, P.M.** 2004. Assessment of the effectiveness of support vector machines for hyperspectral data. Future Generation Computer Systems. 20, 1215–1225.
 - **Programa de Observación de la Tierra de la Unión Europea.** Disponible en: <https://www.copernicus.eu/es> (último acceso 30/04/2021).
 - **¿Qué es SIG? Sistemas de Información Geográfica. Aeroterra.** Disponible en:
 - **Servicio Geológico de los Estados Unidos.** Disponible en: <https://earthexplorer.usgs.gov> (último acceso 30/04/2021).
 - <https://www.aeroterra.com./es-ar/que-es-gis/introduccion> (último acceso 10/06/2021)
 - <http://www.geodim.es/pdf/Geodim%20SENTINEL-2A.pdf> (último acceso 26/03/2021).

ANEXO

Tabla 10. Planilla de relevamiento a campo: Datos de la visita realizada el 02/01/2020

N° de punto	Coordenadas	Cultivo	Fenología	Densidad	Plagas	Enfermedades	% cobertura	Malezas
3	W 59° 02.899' S 35° 23.509'	Maíz	-	0	-	-	0	no
4	W 59° 02.944' S 35° 23.483'	Maíz	V-R	5 pl/m2	-	roya muy leve	90%	Rama negra/ Unquillo
5	W 59° 02.949' S 35° 23.434'	Maíz	V8	7 pl/m2	-	-	90%	-
6	W 59° 02.979' S 35° 23.419'	Maíz	-	0	-	-	60%	Unquillo y gramilla
8	W 59° 03.029' S 35° 23.370'	Canal sin agua	-	-	-	-	95%	-
9	W 59° 03.040' S 35° 23.337'	Maíz	R	5 pl/m2	-	-	95%	Unquillo
10	W 59° 02.921' S 35° 23.405'	Monte	Esquina del monte					
11	W 59° 04.023' S 35° 23.264'	Camino						
12	W 59° 04.320' S 35° 22.378'	Camino						
13	W 59° 04.293' S 35° 21.876'	Monte	Esquina del	del	campo			
14	W 59° 03.894' S 35° 22.174'	Camino	atrás					
15	W 59° 03.852' S 35° 22.240'	Soja	En flor	36 pl/m2	-	-	100%	gramilla
16	W 59° 03.924' S 35° 22.226'	Soja	En flor	40 pl/m2	-	-	100%	maíz guacho
17	W 59° 03.912' S 35° 22.338'	Monte						
18	W 59° 04.023' S 35° 22.443'	Corral	y	molino				
19	W 59° 03.974' S 35° 22.472'	Soja	Entrando en flor	48 pl/m2	1 chinche		60%	Gramilla, rama negra, trebol
20	W 59° 03.837' S 35° 22.386'	Monte						

21	W 59° 03.460´ S 35° 22.494´	Camino						
22	W 59° 03.705´ S 35° 22.476´	Soja	R, Saliendo flor	37 pl/m2	-	-	95%	no
23	W 59° 03.666´ S 35° 22.504´	Maíz 2°	V	9 pl/m2	isoca (helicov erpa)	-	40%	Unquillo, quinoa, abrojo.

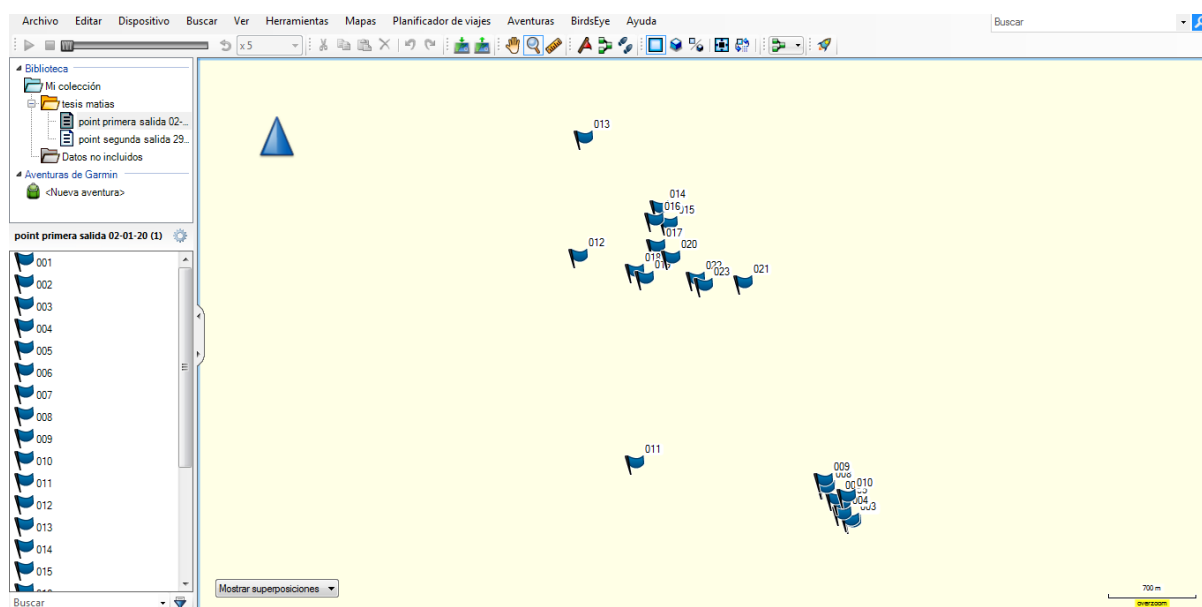


Figura 8. Vista de la distribución de puntos extraídos del GPS a Garmin BaseCamp 02/01/2020

Tabla 11. Planilla de relevamiento a campo: Datos de la visita realizada el 22/02/2020

N° de punto	Coordenadas	Cultivo	Fenología	Densidad	Plagas	Enfermedades	% cobertura	Malezas
3	W 59° 02.898' S 35° 23.507'	Maíz	R	6 pl/m2	-	-	87%	no
4	W 59° 02.945' S 35° 23.482'	Maíz	R	6 pl/m2	-	roya	85%	Capin
5	W 59° 02.949' S 35° 23.434'	Maíz	R	7 pl/m2	-	-	85%	-
6	W 59° 02.982' S 35° 23.418'	Maíz	-	0	-	-	-	Capin
8	W 59° 03.031' S 35° 23.371'	Canal sin agua	-	-			100%	Unquillo, pasto perdiz, rama rengra
9	W 59° 03.039' S 35° 23.338'	Maíz	R	5 pl/m2	-	-	85%	Unquillo
10	W 59° 02.920' S 35° 23.405'	Monte	Esquina del monte					
11	W 59° 04.023' S 35° 23.264'	Camino						
12	W 59° 04.320' S 35° 22.378'	Camino						
13	W 59° 04.293' S 35° 21.876'	Monte	esquina	del	campo			
14	W 59° 03.894' S 35° 22.174'	Camino	atrás					
15	W 59° 03.854' S 35° 22.240'	Soja	R5	-	-	-	100%	1 rama negra
16	W 59° 03.925' S 35° 22.226'	Soja	R5	-	-	-	100%	no
17	W 59° 03.912' S 35° 22.338'	Monte						
18	W 59° 04.023' S 35° 22.443'	Corral	y	molino				
19	W 59° 03.977' S 35° 22.471'	Soja	R3	-	-	-	95%	1 rama negra
20	W 59° 03.837' S 35° 22.386'	Monte						
21	W 59° 03.460'	Camino						

	S 35° 22.494'							
22	W 59° 03.704' S 35° 22.474'	Soja	R3	-	-	-	100%	yuyo colorado
23	W 59° 03.666' S 35° 22.506'	Maíz 2°	R	8 pl/m2	isoca (helicov erpa)	-	85%	no
Nuevos Puntos de Campos Vecinos								
24	W 59° 03.140' S 35° 23.457'	Maíz						
25	W 59° 03.400' S 35° 23.368'	Soja						
26	W 59° 03.528' S 35° 23.345'	Pastizal						
27	W 59° 03.719' S 35° 23.319'	Maíz						
28	W 59° 03.855' S 35° 23.294'	Pastizal						
29	W 59° 04.034' S 35° 23.265'	Pastizal						
30	W 59° 04.151' S 35° 23.248'	Soja						
31	W 59° 04.229' S 35° 23.232'	Soja						
32	W 59° 04.379' S 35° 23.171'	Soja 2°						
33	W 59° 04.371' S 35° 23.055'	Pastizal						
34	W 59° 04.355' S 35° 22.838'	Pastizal						
35	W 59° 04.342' S 35° 22.645'	Soja						

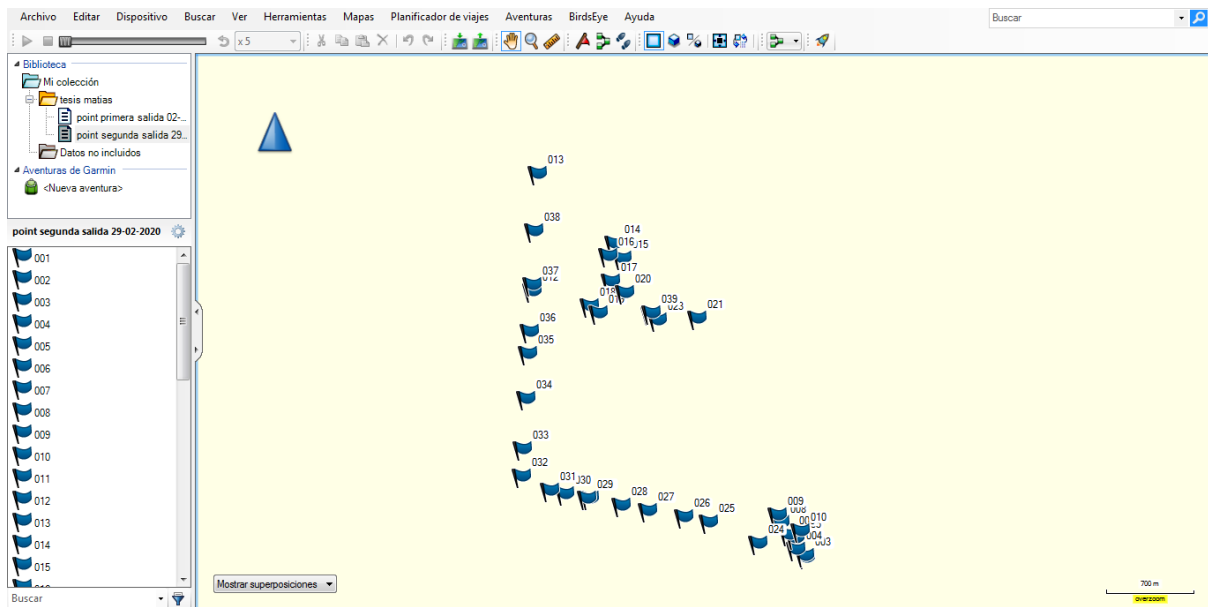


Figura 9. Vista de la distribución de puntos extraídos del GPS a Garmin BaseCamp primera visita 02/01/2020 y segunda visita 22/02/2020.

Sentinel 2

Noviembre:

Tabla 12. Distancia mínima

Clasificación	Referencia						Area (m2)	Wi
	No dato	Agua	Monte	Pastizal	Maiz 1ra	Soja 1ra		
No dato							33.323.484	57%
Agua		1%	0%	0%	0%	0%	688.582	1%
Monte		0%	10%	0%	0%	0%	5.953.712	10%
Pastizal		0%	1%	13%	0%	0%	7.966.752	14%
Maiz 1ra		0%	1%	0%	10%	1%	7.094.848	12%
Soja 1ra		0%	0%	0%	1%	4%	3.696.042	6%
Total		2%	12%	13%	11%	5%	58.723.420	
Area (m2)	0	941.934	6.898.334	7.796.269	6.745.206	3.018.194	58.723.420	

Precisión total [%] =38,3305
 Clasf. Kappa [Adim.] =0,3527

Tabla 13. Mapeo ángulo espectral

Clasificación	Referencia						Area (m2)	Wi
	No dato	Agua	Monte	Pastizal	Maiz 1ra	Soja 1ra		
No dato							33.323.484	57%
Agua		1%	0%	0%	0%	0%	663.179	1%
Monte		0%	6%	0%	0%	0%	3.877.164	7%
Pastizal		0%	2%	16%	0%	0%	10.319.234	18%
Maiz 1ra		1%	1%	0%	9%	2%	7.195.760	12%
Soja 1ra		0%	0%	0%	2%	4%	3.344.600	6%
Total		2%	9%	16%	10%	6%	58.723.420	
Area (m2)	0	1.224.997	5.251.755	9.472.806	6.028.349	3.422.030	58.723.420	

Precisión total [%] =35,4265
 Clasf. Kappa [Adim.] =0,3200

Diciembre:

tabla 14. Distancia mínima

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2da	Monte	Pastizal		
No dato									33.323.484	57%
Agua		1%	0%	0%	0%	0%	0%	0%	801.596	1%
Maiz 1ra		0%	3%	0%	0%	0%	0%	0%	2.250.169	4%
Maiz 2da		0%	0%	1%	0%	0%	0%	0%	835.400	1%
Soja 1ra		0%	0%	0%	10%	0%	1%	0%	7.108.950	12%
Soja 2da		0%	0%	0%	0%	5%	0%	0%	3.255.089	6%
Monte		0%	2%	0%	0%	0%	2%	0%	2.365.683	4%
Pastizal		0%	0%	0%	0%	0%	0%	15%	8.783.050	15%
Total		2%	6%	1%	11%	5%	3%	15%	58.723.420	
Area (m2)	0	1.224.114	3.299.278	835.400	6.171.186	3.183.704	1.926.171	8.760.084	58.723.420	

Precisión total [%] =37,4654
 Clasf. Kappa [Adim.] =0,3472

Tabla 15. Mapeo ángulo espectral

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2da	Monte	Pastizal		
No dato									33.323.484	57%
Agua		1%	0%	0%	0%	0%	0%	0%	898.107	2%
Maiz 1ra		0%	4%	0%	0%	0%	0%	0%	3.155.777	5%
Maiz 2da		0%	0%	4%	0%	1%	0%	0%	2.593.610	4%
Soja 1ra		1%	0%	0%	8%	0%	1%	0%	5.786.192	10%
Soja 2da		0%	0%	0%	0%	4%	0%	0%	3.135.875	5%
Monte		0%	2%	0%	0%	0%	2%	0%	2.896.646	5%
Pastizal		0%	2%	0%	0%	0%	1%	10%	6.933.729	12%
Total		3%	9%	4%	8%	6%	4%	11%	58.723.420	
Area (m2)	0	1.561.014	4.998.466	2.115.859	4.884.230	3.285.273	2.387.839	6.167.256	58.723.420	

Precisión total [%] =33,6990
 Clasf. Kappa [Adim.] =0,3150

Febrero:

Tabla 16. Distancia mínima

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2d Monte	Pastizal			
No dato									33.323.484	57%
Agua		2%	2%	0%	0%	0%	0%	0%	2.926.850	5%
Maiz 1ra		1%	4%	1%	0%	0%	0%	0%	3.225.886	5%
Maiz 2da		0%	0%	3%	1%	0%	0%	0%	1.998.239	3%
Soja 1ra		0%	0%	0%	8%	0%	1%	0%	5.519.760	9%
Soja 2da		0%	0%	1%	0%	0%	0%	0%	1.104.532	2%
Monte		0%	0%	0%	1%	0%	2%	0%	1.477.277	3%
Pastizal		1%	0%	0%	0%	0%	1%	14%	9.147.394	16%
Total		4%	6%	5%	10%	0%	4%	14%	58.723.420	
Area (m2)	0	2.074.095	3.596.331	3.002.525	5.699.491	0	2.549.171	8.478.323	58.723.420	

Precisión total [%] =31,7631
 Clasf. Kappa [Adim.] =0,2895

Tabla 17. Mapeo ángulo espectral

Clasificación	Referencia								Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Soja 1ra	Soja 2da	Monte	Pastizal		
No dato									33.323.484	57%
Agua		2%	3%	0%	0%	0%	0%	0%	2.791.134	5%
Maiz 1ra		2%	4%	0%	0%	1%	0%	0%	3.714.844	6%
Maiz 2da		0%	0%	2%	0%	0%	0%	0%	1.143.237	2%
Soja 1ra		0%	0%	0%	8%	0%	1%	0%	5.375.643	9%
Soja 2da		0%	0%	0%	0%	1%	0%	0%	863.603	1%
Monte		0%	0%	0%	1%	1%	3%	0%	3.039.963	5%
Pastizal		1%	0%	0%	0%	0%	1%	13%	8.471.513	14%
Total		4%	7%	2%	9%	3%	5%	13%	58.723.420	
Area (m2)	0	2.194.144	4.073.974	1.221.182	5.401.880	1.555.582	3.127.844	7.825.331	58.723.420	

Precisión total [%] =31,6585
 Clasf. Kappa [Adim.] =0,2901

Abril:

Tabla 18. Distancia mínima

Clasificación	Referencia										Area (m ²)	Wi
	No dato	Agua	Maiz 1ra	Maiz 2da	Maiz rast	Soja Rast	Soja 2da	Soja 1ra	Monte	Pastizal		
No dato											33.323.484	57%
Agua		1%	0%	0%	0%	0%	0%	0%	0%	0%	465.256	1%
Maiz 1ra		0%	4%	0%	0%	0%	0%	0%	0%	0%	2.203.063	4%
Maiz 2da		0%	0%	4%	0%	0%	0%	1%	1%	0%	3.295.894	6%
Maiz rastrojo		0%	0%	0%	1%	0%	0%	0%	0%	0%	475.357	1%
Soja Rastrojo		0%	0%	0%	0%	1%	0%	0%	0%	0%	737.288	1%
Soja 2da		0%	0%	0%	0%	0%	3%	0%	1%	1%	2.872.443	5%
Soja 1ra		1%	1%	0%	0%	0%	0%	7%	0%	0%	5.777.291	10%
Monte		0%	0%	0%	0%	0%	1%	0%	3%	0%	2.656.218	5%
Pastizal		0%	0%	0%	0%	0%	1%	0%	1%	10%	6.917.127	12%
Total		2%	5%	4%	1%	1%	5%	8%	6%	12%	58.723.420	
Area (m ²)	0	924.931	2.924.067	2.509.664	472.919	703.836	2.813.548	4.576.463	3.403.017	7.071.491	58.723.420	

Precisión total [%] =34,3524
 Clasf. Kappa [Adim.] =0,3222

Tabla 19. Mapeo ángulo espectral

Clasificación	Referencia										Area (m2)	Wi
	No dato	Agua	Maiz 1ra	Maiz rastrojo	Soja rastrojo	Soja 2da	Soja 1ra	Maiz 2da	Monte	Pastizal		
No dato											33.323.484	57%
Agua		0%	0%	0%	0%	0%	0%	0%	0%	0%	289.535	0%
Maiz 1ra		0%	3%	0%	0%	0%	0%	0%	0%	0%	1.721.606	3%
Maiz rastrojo		0%	0%	1%	0%	0%	0%	0%	0%	0%	470.456	1%
Soja rastrojo		0%	0%	0%	1%	0%	0%	0%	0%	0%	463.555	1%
Soja 2da		0%	0%	0%	0%	3%	0%	0%	1%	0%	2.916.549	5%
Soja 1ra		1%	1%	0%	0%	0%	8%	0%	1%	0%	6.593.188	11%
Maiz 2da		0%	0%	0%	0%	0%	1%	4%	0%	0%	3.322.697	6%
Monte		0%	0%	0%	0%	0%	0%	0%	2%	0%	1.127.435	2%
Pastizal		0%	0%	0%	0%	1%	0%	0%	1%	13%	8.494.916	14%
Total		2%	4%	1%	1%	5%	8%	4%	5%	14%	58.723.420	
Area (m2)	0	1.211.211	2.274.708	432.552	550.576	2.731.142	4.943.323	2.384.496	2.935.223	7.936.705	58.723.420	

Precisión total [%] =33,7265
 Clasf. Kappa [Adim.] =0,3126

Landsat 8a

Noviembre

Tabla 20. Mapeo ángulo espectral

Clasificación	Referencia						Area (m ²)	Wi
	No dato	Agua	Monte	Pastizal	Maiz	Soja		
No dato							34.096.974	57%
Agua		2%	0%	0%	0%	0%	1.227.747	2%
Monte		0%	5%	2%	0%	0%	4.406.927	7%
Pastizal		0%	3%	12%	0%	0%	8.622.130	14%
Maiz		1%	1%	0%	9%	0%	6.516.779	11%
Soja		0%	0%	0%	1%	6%	4.622.952	8%
Total		3%	9%	14%	10%	6%	59.493.509	
Area	0	1776670	5643478	8088215	6057725	3830446	59.493.508	

Precisión total [%] =34,9001
 Clasf. Kappa [Adim] =0,3194

Tabla 21. Distancia mínima

Clasificación	Referencia						Area (m ²)	Wi
	No dato	Agua	Monte	Patizal	Maiz	Soja		
No dato							34.096.974	57%
Agua		2%	0%	0%	0%	0%	1.385.266	2%
Monte		2%	7%	1%	0%	0%	6.296.252	11%
Patizal		0%	1%	12%	0%	0%	7.861.539	13%
Maiz		0%	0%	0%	8%	0%	4.867.782	8%
Soja		0%	1%	0%	2%	5%	4.985.696	8%
Total		5%	9%	13%	10%	5%	59.493.509	
Area	0	2.687.938	5.591.251	7.756.959	6.182.690	3.177.696	59.493.508	

Precisión total [%] =35,0939
 Clasf. Kappa [Adim] =0,3230

Diciembre

Tabla 22. Mapeo de ángulo espectral

Clasificación	Referencia								Area (m ²)	Wi
	No dato	Agua	Soja 1	Soja 2	Maiz 1	Maiz 2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	634.576	1%
Soja 1		1%	10%	0%	0%	0%	1%	0%	7.092.848	12%
Soja 2		0%	0%	0%	0%	0%	0%	10%	5.900.205	10%
Maiz 1		0%	0%	0%	3%	0%	1%	0%	2.528.402	4%
Maiz 2		0%	0%	0%	0%	1%	0%	0%	589.570	1%
Monte		0%	0%	0%	1%	0%	2%	0%	1.734.507	3%
Pastizal		0%	0%	4%	0%	0%	0%	7%	6.916.426	12%
Total		3%	10%	4%	5%	1%	3%	17%	59.493.509	
Area	0	1.677.678	5.734.391	2.470.152	2.856.907	589.570	1.991.980	10.075.856	59.493.508	

Precisión total [%] =23,6747
 Clasf. Kappa [Adim] =0,2060

Tabla 23. Distancia mínima

Clasificación	Referencia								Area (m ²)	Wi
	No dato	Agua	Soja 1	Soja 2	Maiz 1	Maiz 2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	504.060	1%
Soja 1		2%	13%	1%	0%	0%	0%	0%	9.452.029	16%
Soja 2		0%	0%	0%	0%	0%	1%	5%	3.136.875	5%
Maiz 1		0%	0%	0%	4%	0%	1%	0%	3.464.514	6%
Maiz 2		0%	0%	0%	0%	3%	0%	0%	1.789.414	3%
Monte		0%	0%	0%	1%	0%	4%	0%	2.793.034	5%
Pastizal		0%	0%	2%	0%	0%	0%	4%	4.256.609	7%
Total		4%	13%	3%	5%	3%	6%	9%	59.493.509	
Area	0	2.095.314	7.943.831	1.644.257	3.036.474	1.789.414	3.430.352	5.456.893	59.493.508	

Precisión total [%] =28,9942
 Clasf. Kappa [Adim] =0,2633

Febrero

Tabla 24. Mapeo ángulo espectral

Clasificación	Referencia								Area (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Soja 1	Soja 2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	657.979	1%
Maiz 1		1%	7%	0%	0%	1%	0%	0%	5.362.841	9%
Maiz2		0%	0%	2%	1%	0%	0%	0%	2.252.969	4%
Soja 1		0%	0%	0%	6%	0%	1%	0%	4.145.895	7%
Soja 2		0%	0%	0%	0%	2%	0%	0%	1.470.776	2%
Monte		0%	1%	0%	1%	0%	4%	0%	4.265.610	7%
Pastizal		1%	0%	0%	0%	0%	0%	11%	7.240.465	12%
Total		4%	7%	2%	9%	3%	6%	12%	59.493.509	
Area	0	2.147.111	4.399.036	1.270.906	5.215.505	1.840.374	3.391.150	7.132.454	59.493.508	

Precisión total [%] =33,7262
 Clasf. Kappa [Adim] =0,3143

Tabla 25. Distancia mínima

Clasificación	Referencia								Area (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Soja 1	Soja2	Monte	Pastizal		
No dato									34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	776.793	1%
Maiz 1		1%	6%	0%	0%	1%	0%	0%	5.181.919	9%
Maiz 2		0%	0%	3%	2%	0%	1%	0%	3.007.259	5%
Soja 1		0%	0%	0%	6%	0%	1%	0%	4.322.316	7%
Soja 2		0%	0%	0%	0%	2%	0%	0%	1.508.580	3%
Monte		0%	0%	0%	1%	0%	2%	0%	2.321.377	4%
Pastizal		1%	0%	0%	0%	0%	0%	13%	8.278.289	14%
Total		4%	7%	3%	9%	3%	4%	13%	59.493.509	
Area	0	2.204.865	4.089.418	1.751.025	5.326.107	1.761.082	2.452.044	7.811.993	59.493.508	

Precisión total [%] =33,7684
 Clasf. Kappa [Adim] =0,3136

Abril

Tabla 26. Mapeo ángulo espectral

Clasificación	Referencia										Area (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Maiz rastrojo	Soja rastrojo	Soja 2	Soja 1	Monte	Pastizal		
No dato											34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	0%	0%	451.854	1%
Maiz 1		0%	2%	0%	0%	0%	0%	0%	0%	0%	1.234.047	2%
Maiz 2		1%	0%	5%	0%	0%	0%	1%	1%	0%	4.242.207	7%
Maiz rastrojo		0%	2%	0%	0%	0%	0%	0%	0%	0%	958.615	2%
Soja rastrojo		0%	0%	0%	0%	0%	0%	1%	0%	0%	477.057	1%
Soja 2		0%	0%	0%	0%	0%	2%	0%	0%	2%	2.832.638	5%
Soja 1		1%	1%	0%	0%	0%	0%	6%	1%	0%	6.074.826	10%
Monte		0%	0%	0%	0%	0%	0%	0%	3%	0%	1.516.681	3%
Pastizal		0%	0%	0%	0%	0%	2%	0%	1%	9%	7.608.609	13%
Total		3%	5%	5%	0%	0%	5%	8%	6%	11%	59.493.509	
Area	0	1.751.797	2.882.715	2.828.138	0	0	2.684.421	4.983.153	3.807.230	6.459.082	59.493.508	

Precisión total [%] =27,7350
 Clasf. Kappa [Adim] =0,2544

Tabla 27. Distancia mínima

Clasificación	Referencia										Area (m ²)	Wi
	No dato	Agua	Maiz 1	Maiz 2	Maiz rastrojo	Soja rastrojo	Soja 2	Soja 1	Monte	Pastizal		
No dato											34.096.974	57%
Agua		1%	0%	0%	0%	0%	0%	0%	0%	0%	563.467	1%
Maiz 1		0%	2%	0%	0%	0%	0%	0%	0%	0%	1.473.476	2%
Maiz 2		0%	0%	3%	0%	0%	0%	1%	1%	0%	3.194.482	5%
Maiz rastrojo		0%	1%	0%	0%	0%	0%	0%	0%	0%	384.346	1%
Soja rastrojo		0%	0%	0%	0%	0%	0%	2%	0%	0%	1.177.341	2%
Soja 2		0%	0%	0%	0%	0%	2%	0%	0%	0%	1.227.747	2%
Soja 1		1%	1%	0%	0%	0%	0%	6%	1%	0%	5.665.277	10%
Monte		0%	0%	0%	0%	0%	0%	0%	3%	0%	2.002.739	3%
Pastizal		0%	0%	0%	0%	0%	3%	0%	1%	12%	9.707.660	16%
Total		3%	4%	3%	0%	0%	4%	9%	6%	13%	59.493.509	
Area	0	1.647.541	2.579.526	2.007.960	0	0	2.510.172	5.329.128	3.679.849	7.642.359	59.493.508	

Precisión total [%] =30,4627
 Clasf. Kappa [Adim] =0,2790