

Facultad de Ciencias Agrarias y Forestales

UNLP



Trabajo Final de Carrera

Teledetección aplicada al agro. Clasificación de usos del suelo en campos de Mones
Cazón, Partido de Pehuajó.

Modalidad: Investigación

ALUMNOS:

Andreucci, Pablo Nicolás

Legajo: 26179/8

DNI: 34.770.373

Mail: pablo.andreucci.89@gmail.com

Teléfono: 221-6128817

Argüero, Federico Ramón

Legajo: 27438/3

DNI: 38.865.764

Mail: federico.arguero@hotmail.com

Teléfono: 2396-423659

Director: Dr. Sebastián Besteiro

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

Lugar de Trabajo: Curso de Topografía. Facultad de Cs. Agrarias y Forestales.
UNLP

Fecha de entrega: Lunes 30 de mayo de 2022

AGRADECIMIENTOS

A la Universidad Nacional de La Plata y en especial a la Facultad de Ciencias Agrarias y Forestales. Los autores se llevan los más gratos y bellos recuerdos de nuestra querida Facultad, a la que siempre desearemos volver y ser bienvenidos, como en casa. Gracias por abrirnos las puertas a personas tan valiosas: los profesores y los amigos.

A nuestros tutores:

Al Ing. Agrónomo Mariano Barragán, muchas gracias por el apoyo y el acompañamiento brindado al equipo de trabajo, por compartir su tiempo, sus experiencias y conocimientos, y por fomentar inquietudes en los estudiantes que generen el crecimiento y la superación propia en esta etapa de aprendizaje.

Al Dr. Ing. Forestal Sebastián Besteiro, un especial agradecimiento al él por la vocación y la motivación constantes puestas para la realización de este trabajo, por su destacada calidad como docente y por sobre todas las cosas, como persona. Un ejemplo de humildad y compañerismo. Muchísimas gracias Sebastián.

A nuestros padres:

No hay suficientes palabras de agradecimiento que gratifiquen el invaluable esfuerzo y sacrificio que han hecho nuestros padres para acompañarnos y guiarnos en todas nuestras elecciones y deseos.

INDICE

INDICE	3
RESUMEN.....	4
INTRODUCCIÓN.....	5
El surgimiento y la utilidad de la teledetección.....	6
Aplicaciones de la clasificación de cultivos agrícolas mediante teledetección.	7
OBJETIVO GENERAL.....	8
OBJETIVOS ESPECÍFICOS	8
MATERIALES Y MÉTODOS	10
Caracterización zonal del área de trabajo.....	10
Periodo de trabajo.....	12
Área de trabajo y mapeo supervisado del suelo	12
Área de muestreo y verdad de campo	15
Imágenes satelitales, programa espacial y sensor remoto	15
Sistemas de información geográfica (GIS) y Complemento SCP	16
Clasificación supervisada.....	17
Etapa de campo.....	18
Etapa de gabinete.....	18
RESULTADOS Y ANÁLISIS.....	24
Caracterización de la zona de estudio	24
Verdad de campo.....	26
Imágenes Satelitales.....	28
Clasificación supervisada multitemporal	31
Validación de la clasificación supervisada	34
Usos del suelo en el área de trabajo.....	35
Clasificación multitemporal vs fecha única.....	38
Eventos agroclimáticos destacables	41
Ventajas y desventajas sobre las distintas vías de descarga de imágenes satelitales	41
CONCLUSIONES.....	42
BIBLIOGRAFÍA.....	44
ANEXOS.....	47

RESUMEN

La teledetección consiste en adquirir a través de sensores de observación, información de un objeto concreto o un área. Una de sus principales aplicaciones en el ámbito agrícola es la clasificación de cultivos. La presente investigación se basó en el análisis multitemporal de la cobertura vegetal de las imágenes Landsat-8 de un área específica rural de la localidad de Mones Cazón, abarcando los meses que transcurren desde octubre del año 2020 a abril del año 2021, mediante el uso de la clasificación supervisada. La metodología consistió en determinar el área de trabajo seguido de la adquisición de imágenes a través de la plataforma del Servicio Geológico de los Estados Unidos, el tratamiento de los datos espaciales se efectuó mediante el preprocesamiento (recorte, combinación de bandas, corrección radiométrica, corrección atmosférica), utilizando el complemento SCP para el sensor Landsat-8. Posteriormente se efectuó el procesamiento por medio del algoritmo de clasificación distancia mínima, ejecutado en el software QGIS, a su vez se procedió a la validación de los resultados obtenidos con el cálculo de la matriz de confusión. Los resultados de la clasificación se consideraron como aceptables, arrojando valores de precisión global del 65% y un índice Kappa de 60%. La clase que se encontró con mayor superficie relevada fue maíz, seguida de soja de segunda, soja, pastura/pastizal, maíz tardío, suelo desnudo, agua, girasol e infraestructura. Se concluye que la metodología aplicada representa una herramienta versátil y útil para la recopilación de información y posterior toma de decisiones productivas en el agro.

INTRODUCCIÓN

La producción de alimentos a pequeña y gran escala es cada vez más dinámica, intensa y demandante de información precisa y específica, tal es así, que el sector agrícola-ganadero viene transitando un proceso de desarrollo profundo en la metodología de obtención de datos e incorporación de nuevas tecnologías, en pos de eficientizar todo proceso productivo. En este contexto, podemos mencionar a la clasificación y monitoreo de los cultivos, al emergente avance en la agricultura de precisión (mapas de rendimientos, delimitación de ambientes, dosificación variable, etc.), el desarrollo de los sistemas de posicionamiento global (GPS) y a la teledetección como los campos de conocimiento donde se fundamentan estas nuevas tecnologías aplicadas a la producción agrícola. Particularmente, la teledetección es un campo de acción en permanente crecimiento en el ámbito agrícola, en sintonía con la mayor disponibilidad de imágenes satelitales, otorgada por diferentes sensores y misiones espaciales, así como también las imágenes de alta resolución obtenidas mediante Vehículos Aéreos no Tripulados (VANT) comúnmente conocidos como drones.

Los orígenes históricos de la Teledetección se hallan íntimamente vinculados al desarrollo tanto de la tecnología fotográfica como de la aviación y de la industria aeroespacial, y siempre en torno a usos militares para obtención de información estratégica sobre cartografía y topografía. Desde finales del siglo XX el sensoramiento remoto vuelca su desarrollo disciplinar hacia la utilización de plataformas digitales. Nace así la Teledetección espacial o percepción remota, ciencia destinada a la observación y análisis de la superficie terrestre y a la evaluación de los recursos naturales (Di Leo, 2015).

La etimología de la palabra refiere a la adquisición de información sobre un objeto o fenómeno sin hacer contacto físico con el mismo. En el uso moderno, el término generalmente se refiere a la utilización de tecnología de sensores montados en plataformas espaciales o aéreas que detectan y clasifican fenómenos en la Tierra por medio de ondas electromagnéticas propagadas (ej: luz visible, infrarrojo, etc) (Di Leo, 2015). La intensidad con la que la energía electromagnética es reflejada, varía de acuerdo a la naturaleza física y a las propiedades ópticas de la superficie sobre la cual la energía incide. A partir de la medición de dicha intensidad por los sensores

remotos es que la técnica suministra información (imágenes aéreas) periódica y actualizada del territorio (García Ferrer-Porras 2013).

Por su parte, los Sistemas de Información Geográfica (SIG) son herramientas fundamentales de trabajo en la planificación y gestión territorial. Posibilitan la representación gráfica, la inserción de modelos algorítmico-lógicos y la realización de preguntas complejas. En definitiva, una mayor efectividad en la toma de decisiones (Pueyo Campos, A.1991).

Si bien los SIG y la Teledetección nacen como disciplinas independientes, hoy en día se encuentran estrechamente vinculadas entre sí para obtener cartografía analítica en formato digital.

El surgimiento y la utilidad de la teledetección

Desde tiempos pasados el hombre ha tenido la necesidad y curiosidad de ampliar sus límites de visión y conocimiento del entorno que lo rodea. La naturalidad de su sentido de la visión y la forma geométrica de la faz terrestre lo ha limitado a ver no más allá de lo que conocemos hoy como el horizonte.

La velocidad con la que ha evolucionado la tecnología de Teledetección en su breve historia de desarrollo ha sido de tipo exponencial en relación con el tiempo de la humanidad.

En la actualidad, se cuenta con una serie de ventajas respecto a la técnica de Teledetección sobre imágenes satelitales (Chuvienco, 1995). De manera general se enlistan algunas de ellas:

1. Cobertura global y periódica de la superficie
2. Visión panorámica de gran escala
3. Homogeneidad en la toma de datos
4. Información sobre regiones no visibles del espectro
5. La presentación de las imágenes en formato digital, agilizando el procesamiento de datos y los costos de la operación.

Todas estas ventajas, son complementarias a otras técnicas, como los sistemas geo-referenciados, la fotografía aérea, los drones y las recorridas a campo. La teledetección es una técnica auxiliar, una herramienta muy versátil y de gran soporte en los procesos de diagnóstico, empleada en un gran abanico de disciplinas.

Entre las disciplinas, se destaca especialmente a la producción agropecuaria por ser uno de los sectores más beneficiados por la técnica de observación remota. La dificultad en poder establecer a gran escala y con mayor exactitud el estado del recurso natural y el uso y ordenamiento territorial de la superficie ha creado la necesidad de desarrollar la mencionada técnica y conocer espacial y temporalmente cuales y como son los usos que el hombre le da a la Tierra que habitamos. De tal manera se ha instaurado la utilidad de la teledetección en el sector agropecuario mundial.

Aplicaciones de la clasificación de cultivos agrícolas mediante teledetección

El procesamiento de imágenes satelitales brinda información valiosa para la planificación e implementación de planes estratégicos y/o de contingencia por parte del sector público y privado. Un pronóstico con mayor certidumbre del rendimiento y stock de los cultivos podría aportar mayor claridad en el mercado de granos y permitiría optimizar la logística relacionada con la producción, almacenamiento y distribución de productos primarios, entre otros. (Portillo, 2017).

Instituciones con fines científicos y/o sociales se valen de la clasificación de los cultivos primarios y extensivos para múltiples propósitos. El ejercicio de la técnica da como resultado el estado, la condición de uso y la cobertura presente en la superficie edáfica, a escala regional, local o intra-lote, las rotaciones o secuencias elegidas por los productores, percibir con mayor acierto la sustentabilidad ambiental y socio-económica de los sistemas productivos, etc.

A nivel predial en un establecimiento, es una interesante oportunidad de llevar un registro informatizado sobre la historia del uso del lote, labores culturales y/o de aplicación de insumos, condicionantes edáfo-ambientales, etc., lo que se practica

hoy en día como enfoque agronómico de Manejo Sitio-Específico de la relación suelo-planta-atmósfera (Di Leo, 2015).

En Argentina, por superficie sembrada y réditos económicos, tanto para los productores como para el Estado Nacional, los cultivos estivales son los más destacados. De aquí nace la necesidad, a través de la técnica de clasificación supervisada de imágenes satelitales Landsat, de evaluar y determinar el uso que los productores le dan al suelo en una zona específica de la localidad de Mones Cazón, partido de Pehuajó.

Con la presente tesis se busca validar y desarrollar una técnica que sirva como apoyo para futuras clasificaciones.

OBJETIVO GENERAL

Articular el relevamiento a campo de cultivos implantados, con el procesamiento de imágenes satelitales de mediana resolución, bajo un entorno de Sistemas de Información Geográfica de libre acceso, con la finalidad de identificar remotamente cual es el uso del suelo que elige un productor sobre su establecimiento, y con ello caracterizar la cobertura del suelo en un entorno territorial local.

OBJETIVOS ESPECÍFICOS

Caracterizar brevemente la zona de estudio: Mones Cazón, Partido de Pehuajó.

Reconocer a campo los lotes en estudio y geo-referenciarlos para su procesamiento en un entorno GIS.

Relevar información sobre “verdad de campo”: la cobertura vegetal del suelo y labores culturales de los cultivos presentes durante el periodo estival entre los años 2020 y 2021.

Adquirir las secuencias temporales y espaciales de imágenes satelitales de mediana resolución, necesarias para su procesamiento bajo un entorno GIS de libre acceso.

Generar la clasificación supervisada del cultivo (el uso del suelo) utilizando la plataforma QuantumGis (QGis) y la “verdad de campo” anteriormente mencionada.

Determinar a nivel predial (establecimiento) y local (Mones Cazón) los diferentes usos productivos del suelo.

Realizar una validación del producto obtenido post clasificación y acompañarlo de una medida del nivel de exactitud de la clasificación realizada.

Establecer la conveniencia de un análisis multitemporal frente a uno de fecha única respecto a la clasificación supervisada.

Determinar información complementaria sobre eventos agroclimáticos destacables (sequías, inundaciones, granizo, vientos, etc.)

Identificar ventajas o desventajas sobre las distintas vías de descarga de imágenes satelitales para facilitar un correcto desenvolvimiento en prácticas futuras.

MATERIALES Y MÉTODOS

Caracterización zonal del área de trabajo

La localidad de Mones Cazón, Partido de Pehuajó, Provincia de Buenos Aires, cuenta con una población de 1764 habitantes según el censo realizado en el año 2010, se encuentra a 60km de la ciudad cabecera y se accede a través de La Ruta del Cereal (camino provincial secundario N 107-08). La superficie del Partido es de 456.000 hectáreas aproximadamente y cuenta con 39776 habitantes. Sus coordenadas geográficas son: 35°48'40'' Sur | 61°53'55'' Oeste. (Municipalidad de Pehuajó, 2020)

El clima es templado sub-húmedo, con una precipitación media anual de 950 mm, de distribución estival, teniendo sus temperaturas medias máximas anuales en 21, 8° C y sus mínimas medias anuales en 10° C. (Nocelli, 2017)

Los tipos de suelos prevalentes en el Partido pertenecen al gran grupo de los Hapludoles (Cartas de Suelos de la República Argentina, INTA.). Alrededor del 50% de los suelos en el partido presenta mayor influencia de las series Carlos Salas, Piedritas, Pichincha y Bolívar. En la parte sur del partido, (zona de estudio de este trabajo) predominan suelos de las series Bolívar, Carlos Salas, Piedritas, Pehuajó y Veinticinco de Mayo, cuyas propiedades presentan índices de productividad buena o regular, cada cual con sus características propias presentando en común contener suelos oscuros profundos, de aptitud agrícola ganadera y pendientes menores al 1% lo que origina paisajes caracterizados por poseer planicies más altas que en el sector norte del partido, suavemente onduladas, con algunos bajos inundables y la presencia hacia el sur del partido de lomas medanosas extendidas (Memoria técnica INTA, 2009-2010).

Esta región es denominada (por sus características geomorfológicas, edáficas y de vegetación) como Pampa Interior Plana o Pampa Arenosa (Memoria técnica INTA, 2009-2010). El carácter arenoso de los suelos y la falta de pendiente llevan a que esta región carezca de una red fluvial desarrollada y, por lo tanto, sea considerada como una cuenca de tipo exorreica. Esta característica hace que el área de estudio sea afectada por condiciones climáticas desfavorables como pueden ser intensas lluvias, o por crecientes de los ríos de la Pampa Alta (San Luis y Córdoba), principalmente el río Quinto, esto hace que la cuenca del Salado desborde, y que

vastas zonas productivas agrícola-ganaderas se vean perjudicadas por graves inundaciones, incluso con formaciones de lagunas y bañados (humedales). Dardo Rocha en el año 1883 dio el nombre al partido, Pehuajó, debido al término de origen guaraní “terreno pantanoso” o “estero profundo” (Municipalidad de Pehuajó, 2020). Esto es relevante a la hora de analizar las imágenes satelitales y llevar a cabo los distintos tipos de producciones, a su vez ayuda a comprender la aparición de estos bajos inundables temporales y permanentes que se ven en distintas épocas del año.

Con respecto a las capacidades de uso de los suelos del partido, se observa que prevalecen con un 65 % de la superficie total las clases III y IV (ambas aptas para actividades agrícolas), y gran parte de la superficie restante representada por suelos con capacidades de usos clases VI y VII (praderas y pasturas naturales) (Memoria técnica INTA, 2009-2010). Es así como sobre los suelos de este Partido se desarrollan tanto las actividades agrícolas como las ganaderas (Ministerio de Agroindustria, 2015).

En cuanto a los recursos forrajeros de la región se discriminan en 2 grandes grupos: los recursos exóticos (o implantados por el hombre) y los recursos nativos (autóctonos). Entre los exóticos de mayor relevancia, se encuentran las comunidades denominadas agronómicamente praderas polifíticas, compuestas por las especies: Festuca, Phalaris, Lolium, Dactylis, Trifolium, Medicago, Agropyron. Entre los recursos autóctonos, se encuentra el pastizal pampeano, conocido comúnmente como praderas de uno o dos estratos herbáceos de cobertura variable, donde predominan distintas gramíneas agrupadas según la posición topográfica y características edáficas en distintas comunidades vegetales: pradera de mesófitas, pradera húmeda de mesófitas, pradera de hidrófitas y estepa de halófitas (Burkart *et al*, 2010).

Como fue mencionado, la actividad agrícola zonal tiene una fuerte presencia regional. En la Tabla 1 se exhiben los cultivos de mayor importancia en función de la superficie ocupada por ellos y sus rendimientos obtenidos, resultado del promedio entre las campañas 2009-2010 y 2019-2020 en el partido de Pehuajó.

(Tabla 1, aquí. Ver en Anexos)

Periodo de trabajo

El periodo de trabajo para la presente tesis fue determinado en función de las épocas de siembra-cosecha de los cultivos mayoritarios de la zona (descritos en la tabla 1) tomándose entre estos a los de tipo estivales por ser los que se encuentran en estado vegetativo al momento del desarrollo de la investigación, resultando los mismos comprendidos entre los meses de octubre del año 2020 y abril del año 2021.

Área de trabajo y mapeo supervisado del suelo

El área de trabajo está circunscrita en el interior de un polígono rectangular que abarca la totalidad de los datos de campo relevados y volcados en un entorno GIS georreferenciado en coordenadas planas.

El polígono mencionado se posiciona en una zona rural de Mones Cazón de aproximadamente 22.000 hectáreas que, como se expresó en el párrafo anterior y se visualiza en la Figura 1, contiene los lotes visitados y los datos recogidos a campo que se expresarán más adelante. Esta información es la que será oportunamente utilizada en la clasificación y la que será consignada como verdad de campo.




Figura 1. Ilustración del sitio del área de trabajo y sus rutas de acceso.

Cabe mencionar que la extensión de esta área de trabajo surge de la posibilidad de contar con el apoyo de un productor agropecuario local, que además de permitir el acceso a sus campos, representa un referente valioso a la hora de contrastar los resultados de nuestra clasificación, producto de que recorre diariamente los caminos sobre los cuales se relevó la información e identifica las distintos potreros y sus coberturas.




Figura 2. Detalle del área de trabajo con la ubicación de los campos del productor y la conexión vial entre ellos.

El polígono también establece el área de búsqueda en las plataformas de descarga de las imágenes satelitales. La superficie de esta área se halla con sus coordenadas cartográficas en el sistema universal transversal de Mercator (UTM) en la cuadrícula H-20 (al sur del ecuador) sobre el mapa terráqueo y definido dentro de los vértices:

- Superior izquierdo, coordenadas X: 587175 metros Y: 6001585 metros
- Inferior derecho, coordenadas X: 599684 metros Y: 5983585 metros

(X: metros desde el Meridiano hacia el Oeste, Y: metros hacia el ecuador)

(Manual de usuario QuantumGis)

Área de muestreo y verdad de campo

El área de muestreo queda delimitada dentro del polígono área de trabajo mencionado en párrafos anteriores, definiendo lo que más adelante será el vector polígono verdad de campo. En la Figura 4, compartida en resultados, se visualiza un vector polígono con los datos relevados a campo, expresando los cultivos implantados cubriendo el suelo al momento presente del periodo agrícola-ganadero estival entre los años 2020-2021, constatando visualmente recursos forrajeros perennes y cultivos estivales anuales como , soja de primera, soja de segunda, maíz, maíz tardío, maíz de segunda, girasol, pasturas, además de lo intrínseco a la actividad pecuaria, forma parte del paisaje relevando espejos de agua de tipo permanentes y temporarios (bajos anegables), infraestructuras, rutas, caminos rurales y poblado.

Imágenes satelitales, programa espacial y sensor remoto

Las imágenes satelitales correspondientes a los lotes geo-referenciados y cultivos caracterizados en la recorrida a campo, fueron las provistas por el programa espacial Landsat Data Continuity Mission, satélite Landsat 8, equipado con 2 sensores remotos, siendo de utilidad en la presente investigación el sensor radiómetro OLI (Operational Land Imager) que opera en nueve longitudes de onda en el rango de 0.433-2.300 μ m y proporciona imágenes con una resolución máxima de 15m utilizando avanzadas tecnologías de imágenes espaciales. Por conveniencia

en el número de imágenes disponibles para el periodo de tiempo de trabajo, se seleccionan de cada una de las imágenes, aquellas bandas que las componen y que se caracterizan con resolución espacial de 30 metros, debido a que son estas las bandas del espectro electro-magnético que nos permiten mediante procesamiento diferenciar coberturas terrestres. (Sistema de observación terrestre, EOS) Estas imágenes, adquiridas de los servidores del Servicio Geológico de los Estados Unidos (USSG) poseen un preprocesado al servicio del usuario, donde se corrigen interferencias atmosféricas y calibraciones de la posición geográfica de las imágenes propias del ángulo satelital respecto a la tierra, la altimetría terrestre y la forma elipsoidal del planeta (Fuente: USGS) Los criterios de selección para la descarga de imágenes fueron:

1. Abarcar el área de trabajo previamente definida
2. Tener una fecha de adquisición (sensing date) correspondiente al lapso de tiempo que habrá entre la primera quincena de octubre año 2020 y primera quincena de abril año 2021
3. Poseer un porcentaje de nubes inferior al 20%

Sistemas de información geográfica (GIS) y Complemento SCP

Los Sistemas de Información Geográfica se desarrollan como una tecnología que permite la manipulación y el análisis de los datos geográficos (Gantz, 1990; Lang & Speed, 1990).

Las imágenes ópticas-electrónicas fueron procesadas mediante software QGIS, programa de soporte de GIS, de libre acceso y código abierto. QGIS es un proyecto oficial de Open Source Geospatial Foundation (OSGeo). Corre sobre Linux, Unix, Mac OSX, Windows y Android y soporta numerosos formatos y funcionalidades de datos vector, datos ráster y bases de datos. Entre las funciones que permite operar se encuentran: ver datos (Combinaciones de datos vectoriales y ráster (en 2D o 3D) en diferentes formatos y proyecciones sin conversión a un formato interno o común), explorar datos y componer mapas, crear, editar gestionar y exportar datos (capas vectoriales y ráster en distintos formatos), analizar datos, publicar mapas en internet, extender funcionalidades Qgis a través de complementos (Qgis se puede adaptar a

sus necesidades especiales con la arquitectura de complemento extensible y bibliotecas que se pueden utilizar para crear complementos). (Qgis, 2021)

SCP (semi-automatic classification plugin) es un complemento gratuito de código abierto para Qgis que permite la clasificación supervisada de imágenes de detección remota, proporcionando herramientas para la descarga, el preprocesamiento y el postprocesamiento de imágenes. (Congedo, 2021).

Clasificación supervisada

En la presente tesis se realizaron dos clasificaciones supervisadas sobre imágenes satelitales, entendiéndose a éstas como el proceso en el que píxeles (unidad homogénea en color más pequeña que contiene y conforma una imagen) de una imagen de identidad conocida, se utilizan para clasificar píxeles de identidad desconocida. Aplicada la metodología sobre imágenes referentes a sitios agronómicos, se logra obtener información de manera remota sobre las actividades realizadas en los mismos.

Los distintos colores percibidos sobre una imagen satelital responden a que los píxeles componentes de la misma, representan la reflectividad energética emitida por los objetos presentes en el entorno terrestre al momento en el que el instrumento óptico satelital capta la reflectividad. En otras palabras, todos los objetos al recibir energía proveniente de una fuente externa emiten (o reflejan) en forma inversa a la que reciben, parte de esta energía que no es absorbida. Esta energía, componente del espectro electromagnético, es capturada por los instrumentos ópticos a bordo de plataformas espaciales y procesada en formato de imagen satelital.

El trabajo realizado por los tesisistas consta de dos etapas fundamentales, una de campo y otra de gabinete, serán descritas a continuación.

Respondiendo a uno de los objetivos específicos de este trabajo es que se procede a realizar dos clasificaciones, una multitemporal con varias imágenes apiladas (como será descrito en apartados siguientes) que abarcan el periodo de trabajo y otra con una sola imagen correspondiente al mes de enero, mes en el que los cultivos implantados se encuentran con un buen desarrollo y ya bien definidos. Para luego

realizar la comparación de resultados y analizar qué método es más conveniente a la hora de interpretar y definir los usos del suelo para una determinada zona.

En la etapa de gabinete se explicará solo el recorrido para la clasificación multitemporal, ya que la clasificación con una sola imagen consta de los mismos pasos, obviando el apilamiento de varias imágenes.

Etapa de campo

En el trabajo de campo se realizó un reconocimiento de la zona transitada y el relevamiento-monitoreo de datos acerca de lotes y usos agronómicos del suelo para el entrenamiento y validación de la clasificación supervisada, dando origen así a la verdad de campo, anteriormente mencionada en Área de Muestreo. La verdad de campo contiene también información sobre construcciones, poblados y bañados que existen en el área mencionada. Los datos obtenidos del monitoreo que conforman la verdad de campo son: información geográfica localizada, perímetro de lotes con sus coberturas vegetales presentes y nomenclatura identificatoria, es decir qué uso se le está dando al suelo en el momento de la recopilación de información.

Con el acompañamiento de un productor agropecuario idóneo y lugareño se recorrió la zona rural esquematizada en la figura 4. Se transitaron los caminos que unen los establecimientos que pertenecen al productor, recopilando los datos de gran parte de los lotes que se encontraban a la vera de los mismos, etiquetando a qué cultivo pertenecía cada uno, mejorando la confianza de los datos relevados. Esto es de suma importancia debido a que fue la base para dar origen de datos de entrada al complemento SCP (training input) y evaluar la precisión de la propia clasificación.

Etapa de gabinete

En la segunda etapa, se comenzó corroborando por interpretación con Google Earth Pro el área de muestreo etiquetada en el monitoreo a campo, sobre la interfaz principal del Qgis (canvas o lienzo) y con apoyo de las imágenes en alta definición del Google Earth se delimitan los lotes del área de muestreo creando vectores polígonos, definiendo una capa que contiene al conjunto: la verdad de campo, información idéntica al área de muestreo. Cuando se construyen archivos vectoriales en Qgis (puntos, líneas, polígonos) se pueden asignar atributos que los caractericen,

aquí se editó: números ID, límites, superficies y clase de cobertura presente sobre ellos en el periodo de trabajo. La información del terreno relevada se clasificó y agrupó de acuerdo a sus características en 4 macro clases (cultivos, construcciones, suelo desnudo y agua) y un total de 9 clases (Maíz, maíz tardío, soja, soja de segunda, girasol, pastizales/pasturas, agua, construcciones, y suelo desnudo).

Siguiendo con la clasificación en sí, se dividió a su vez dicho trabajo en 3 etapas para que se logre una mejor interpretación de lo realizado:

Preprocesamiento:

En esta etapa de gabinete se reúnen los materiales de trabajo y se los acondiciona para el proceso. A lo largo de todo el trabajo se investigan, estudian y se practican las herramientas, materiales y procesos necesarios para alcanzar los objetivos planteados. En esta etapa cobran mayor protagonismo las acciones mencionadas.

Cuando se reunieron y acondicionaron los materiales de trabajo se descargaron aplicaciones con complementos softwares y las imágenes satelitales.

Se descargó la última versión estable del programa Quantum Gis y dentro del mismo se descargaron aplicaciones complementos que mejoran la herramienta, entre ellas: Semi-automatic classification plugin, la herramienta principal, Quick Map Services que brinda una serie de distintas capas con variada información geográfica, entre ellas, Google Satélite y Bing Aerial (de mayor resolución espacial), Open Street Maps, también aplicaciones de ensamblaje de capas vectoriales (point sampling tool), Google Earth Pro, Visor Geolnta, entre otras.

Las imágenes se descargaron libremente de las plataformas de descarga del Servicio Geológico de Estados Unidos, mediante previa creación de cuenta de usuario, aunque cabe mencionar, que desde el propio complemento SCP se puede proceder desde sus herramientas a la descarga de productos satelitales, promoviendo la versatilidad de este software gratuito.

Lo más destacado en esta instancia previa se fundamenta en: reducir (recortar) en tamaño las imágenes, combinar a elección las bandas electromagnéticas que componen las imágenes y combinar todas las imágenes en una sola fuente de datos sobre la cual practicar la clasificación.

Las imágenes tomadas por el satélite, que poseen una superficie original de 3.422.500 hectáreas aproximadas, son recortadas a las 22000 hectáreas del Área de trabajo.

Las bandas de cada imagen en particular, y todas las imágenes en general son combinadas en un solo archivo que unifica todos los datos detectados por el sensor satelital para el posterior procesamiento del algoritmo de clasificación. Este archivo, denominado StackLayer (traducción al inglés de “apilamiento o agrupamiento de bandas”) combina la información de la energía reflejada por los cultivos a lo largo de todo el periodo de trabajo, según los diferentes estados fenológicos que atravesaron las cubiertas vegetales presentes en el área referida.

El fin que justifica el objetivo de preprocesado es adecuar y reducir el material de trabajo para mejorar y agilizar el procesado propio del ordenador.

Procesamiento:

Esta instancia implica el entrenamiento del software y la elección del algoritmo para obtener la clasificación propiamente dicha. Durante el entrenamiento de entrada (training input) se construyen polígonos sobre el área de muestreo que demarcan regiones de interés (roi's) sobre la imagen. Al construirlos se especifica como dato de entrada que el área de interés pertenece a una de las macro-clases y a una de las clases ya descritas. De esta manera el software al clasificar según el algoritmo elegido, y en función a la firma espectral emitida por la cobertura presente dentro de la región de interés (Land Cover Signature), determina a qué clase pertenecen el resto de los píxeles que no fueron usados en el entrenamiento de entrada. Para el entrenamiento de la clasificación se utilizó la mitad de la superficie de cada clase relevada como verdad de campo. La mitad restante de la superficie área de muestreo fue utilizada para evaluar la precisión de los resultados post clasificación.

El algoritmo utilizado fue distancia mínima, seleccionado debido a los buenos resultados finales expresados sobre el área de trabajo y en comparación a máxima verosimilitud y mapeo de ángulo espectral. En Resultados y Análisis se aprecia mejor esta elección.

Postprocesamiento:

El fundamento de esta instancia es que como todo proceso de clasificación de imágenes está sujeto a errores de interpretación y desaciertos por distintas razones, y debido a eso debe someterse a una evaluación de la precisión del trabajo realizado, para tener el poder de aceptar o desestimar el resultado final. Para alcanzar el objetivo específico planteado básicamente se contrastan sitios de la verdad de campo denominados puntos de muestreos, con los mismos sitios referidos a la imagen satelital (píxeles) que hayan sido clasificados por el programa. A simple vista los resultados posibles del contraste son dos: si corresponde la clasificación con la verdad de campo, o, no corresponde lo clasificado con la verdad de campo. Existen una serie de operaciones matemáticas e índices que ayudan a materializar ciertamente con mayor precisión esta instancia de evaluación. Por ejemplo, la matriz de confusión o matriz de error: es una tabla de contingencia que sirve como herramienta estadística para el análisis de observaciones emparejadas. Como un estándar para informar sobre la exactitud temática de cualquier producto de datos derivados de la teledetección. Esta misma herramienta puede ser utilizada para evaluación de la calidad temática de cualquier tipo de dato espacial (p.ej. parcelas catastrales, cubiertas vegetales, red viaria, base de datos topográfica, etc.). (López *et al*, 2018). Resumiendo, es una matriz cuadrada en la que se compara la clasificación de la imagen con la verdad de campo. A través de la matriz de confusión se evalúa la exactitud de la clasificación, situando en las filas las clases o categorías de nuestro mapa y en las columnas las mismas clases para la verdad de campo. (Boca *et al.* , *s.f.*). Los elementos que aparecen en la diagonal nos indican el número de clasificaciones realizadas correctamente, y aquellos que aparecen fuera suponen migraciones o fugas. Desde el punto de vista de la interpretación de la matriz de confusión, existen dos tipos de errores: de omisión (riesgos del usuario): son los elementos que perteneciendo a esa clase no aparecen en ella por estar erróneamente incluidos en otra (datos por debajo de la diagonal principal de la matriz de confusión) y los de comisión (riesgos del productor): son los elementos que no perteneciendo a una clase aparecen en ella (datos por encima de la diagonal principal de la matriz de confusión).

Existen varios tipos de índices: globales (ofrecen una valoración de la calidad de toda la clasificación), por clase (se emplean en caso de necesitar un mayor nivel de conocimiento sobre una clase concreta), y por caso (analizan el comportamiento estadístico de una sola celda de la matriz). Dentro de los índices globales se encuentra el Coeficiente Kappa, utilizado para este trabajo, su uso está muy extendido. El mismo considera las distribuciones marginales de la matriz de confusión, es decir, las probabilidades a posteriori de pertenencia a una clase. Da idea del % de acuerdo, una vez que se ha eliminado la parte debida al azar.

Una de las características de la aplicación utilizada en este trabajo (SCP) y que da idea de su versatilidad, es la de sintetizar reportes de la clasificación una vez ejecutada. El reporte, que brinda una serie de datos en función de las clases editadas durante el proceso clasificatorio, es un informe de la clasificación. Con la superficie que ocupa cada una de las clases como dato, se ponderó el número de puntos de muestreo para tomar al azar y contrastar a que clase fue clasificado versus la realidad de campo relevada en Área de muestreo. Cabe recordar que la mitad de la verdad de campo fue utilizada para el entrenamiento del programa, entonces quedó disponible para la evaluación la mitad restante de la mencionada área de muestreo.

Para decidir los puntos de muestreo, se utilizó una ecuación estadística para proporciones poblacionales (Salcido, 2018). En función de un margen de error del 5%, un nivel de confianza del 95% y una población de 252890 píxeles, se obtuvo un valor mínimo de puntos de muestreos, que por recomendación bibliográfica (Sensores Remotos UNNE, 2021) fue multiplicada por 2. La población responde al número de píxeles que caben en la imagen recortada de 22000 hectáreas conocida como el Área de trabajo. A continuación, se define la ecuación propuesta por Salcido:

$$n = \frac{Z^2(p * q)}{e^2 + \frac{(Z^2(p * q))}{N}}$$

- n = *Tamaño de la muestra*
- Z = *Nivel de confianza*
- p = *Proporcion de la población con la característica deseada (éxito)*
- q = *Proporcion de la población con la característica deseada (fracaso)*

- $e = \text{Nivel de error dispuesto a cometer}$
- $N = \text{Tamaño de la población}$

Paso seguido y mediante herramientas propias del Qgis, se creó una capa vectorial de puntos sobre la mitad del Área de muestreo, que contiene los puntos al azar que le corresponde a cada una de las 9 clases según la ponderación explicada. Como a cualquier dato vectorial que se le puede editar y crear datos característicos, a cada uno de los puntos de muestreo se le atribuyó un número de ID y el nombre correspondiente a la clase perteneciente en función de la verdad de campo. Concretamente aquí es donde se digitaliza de manera geo-referenciada y sobre la imagen satelital la verdad de campo, generada en la recorrida de transecta. Es crucial que las características o atributos que definen a cada clase en esta capa vectorial sean exactamente iguales a los atributos que definen a cada una de las clases presentes en la clasificación, de lo contrario se obtendrían errores de comparación en la matriz de confusión. Esta capa vectorial de puntos y la clasificación resultante son los datos de entrada de la herramienta SCP Precisión (accuracy assessment) para obtener como dato de salida a la Matriz de Error como los índices globales descritos.

RESULTADOS Y ANÁLISIS

Caracterización de la zona de estudio

Durante la caracterización zonal en la cual se desarrolla este trabajo, se logró corroborar a campo y mediante el análisis e interpretación de imágenes satelitales, que los datos bibliográficos investigados y estudiados corresponden a la realidad presente. A su vez, la bibliografía consultada ayudó a comprender y respaldar las características agroclimáticas y edafoclimáticas, las actividades pecuarias zonales y el porqué de la aparición de espejos de agua.

La zona influyente a la localidad de Mones Cazón se caracteriza por tener suelos de aptitud agrícola ganadera, con texturas franco-arenosas, de escasa o nula pendiente, lo que suele originar periodos de tiempo con áreas anegadas carentes de buen escurrimiento. Vale la aclaración, porque esta característica topográfica cobró interés en la cantidad representativa del paisaje a la hora de realizar la clasificación, lo que condujo a adjudicar a estos bañados de agua una clase determinada. Los cultivos que se relevaron en la zona fueron: maíz, soja, girasol, rastrojos de cultivos invernales, pasturas y pastizales naturales típicos de la región pampeana.

En la Figura 3 se representa un mosaico de imágenes con la información recopilada de la bibliografía. En ella se visualiza la carta de suelos correspondiente al área de trabajo, un stack-layer multitemporal de imágenes, las isotermas medias anuales y las isoyetas de precipitación media anual.

Mapa de Caracterización agro-climática y edáfica del Área de Trabajo, pueblo de Mones Cazón, Partido de Pehuajó.




Figura 3. Caracterización de clima y suelo referente al área de trabajo

Verdad de campo

Se confeccionó un mapa a través de las rutas de acceso a los campos del productor y los lotes aledaños a los mismos, etiquetando a cada lote con la cobertura vegetal presente al momento de la recorrida (26 de diciembre de 2020), dando así origen a la “verdad de campo”, visualizada en la Figura 4. Vector con la que se practica el entrenamiento y validación de la clasificación. Resultó ser la columna vertebral del trabajo, debido a que estos datos fueron los necesarios para generar los puntos de control de la clasificación supervisada.

Con el vector verdad de campo sobre el lienzo de trabajo, y poniendo en práctica herramientas de cálculos y funciones propias al Qgis, resultó que la superficie relevada en el campo fue de aproximadamente 3200 hectáreas, lo que representa cerca del 15% del total del área de trabajo. Este no es un dato menor ya que representa un antecedente de trabajo para futuras experiencias. Permite ajustar la adquisición de datos a la extensión del área de trabajo proyectada (verdad de campo) y conferir una considerable reducción de costos, ya sea económicos y en el tiempo necesario para un mismo nivel de calidad de trabajo.

Mapa Área de Muestreo

Mapa a mayor escala que sobre imagen satelital Google Satellite del pueblo Mones Cazón, representa los caminos rurales y los campos que se emplearon para relevar la verdad de campo.

Mapa de menor escala que mediante polígonos y colores esquematiza los datos recogidos a campo. Información: las clases de cobertura y usos del suelo, georeferenciadas y con límites definidos que componen la clasificación supervisada.




Figura 4. Relevamiento de las clases de coberturas presentes al momento de la recorrida a campo.

La recopilación bibliográfica acerca de las labores culturales que se llevan a cabo en la zona coincidió con lo que el productor relató y los tesisistas pudieron relevar a campo, lo que expresó como resultado que el denominador común es el uso de la técnica siembra directa y barbechos químicos.

Para los cultivos de maíz, girasol y soja la ventana de siembra comúnmente elegida va desde los meses de septiembre a diciembre inclusive, tanto para aquellos cultivos denominados de primera como los de segunda o tardíos. Y la cosecha, para los meses que corren de febrero a junio inclusive. Esta información respalda el periodo de trabajo, mencionado en materiales y métodos.

Imágenes Satelitales

Se adquirieron las imágenes libres y gratuitas de la plataforma de descarga del servicio geológico de Estados Unidos, como fue mencionado en apartados anteriores, cuales Path y Row son 227/085.


Se decidió practicar una reducción del tamaño de las imágenes a 22.000 hectáreas aproximadamente, ajustándose al área de trabajo para una mejor performance de los softwares y adaptándose a las cualidades del computador personal disponible. A su vez se combinaron las bandas electromagnéticas que componen las imágenes con el orden: 2, 3, 4, 5, 6 y 7. En la tabla 4 del apartado de Anexos se ilustra el rango de longitudes de onda en el que se adquieren las bandas mencionadas respecto al rango de longitud de onda espectral. El resto de las bandas que componen las imágenes Landsat (bandas 1, 8 y 9) no fueron utilizadas por ser más representativas para el procesamiento de datos referidos a otras Ciencias y aplicaciones, como lo son: estudios atmosféricos, costeros y marítimos, construcciones civiles, entre otros. Seguidamente se combinaron todas las imágenes en una sola fuente de datos sobre la cual se realizó la clasificación.

En la siguiente figura se exponen dos imágenes, una de ellas es producto de un stack multibandas integrado por 9 imágenes de diferentes fechas, y la otra es producto de un stack multibanda compuesto por una única imagen de un solo día. Ambos stacks contienen imágenes pertenecientes a la ventana de tiempo en la cual se cita este trabajo, semestre comprendido entre octubre del año 2020 y abril del

año 2021. Sobre ambos, se configura un renderizado tomando las bandas 5, 4 y 3 en RGB respectivamente para su visualización, difiriendo entre ellas únicamente en la fecha en la que el satélite ha capturado la imagen, siendo las bandas del stack multitemporal correspondientes al día 30 de octubre del 2020 y las bandas del stack de única fecha correspondientes al día 18 de enero del 2021. Tomando como punto de comparación cualquiera de los 3 lotes resaltados se destaca por interpretación visual, que a simple vista muestran diferencias de la energía reflejada por las coberturas terrestres y captadas por el satélite en diferentes momentos del periodo. Si bien en esta instancia no resulta la discriminación de las clases de cobertura que se espera, resulta una clara diferencia entre las dos fechas, que a sabiendas de que las coberturas terrestres de los lotes son las mismas en ambas fechas, las coberturas presentes visualizadas parecen distintas, pero no lo son. Esta interpretación da razón a seguir trabajando en una clasificación de cobertura terrestre que esté sustentada en la información espectral recogida a lo largo de toda la fenología de los cultivos.

Resultados de las descarga de imágenes satelitales, combinaciones de bandas espectrales y renderizado. Comparación entre una imagen multi-banda versus un apilamiento de varias imágenes multi-banda.

A la derecha, la imagen de stackLayer temporal representando la reflectancia captada por el sensor OLI del satélite Landsat 8 perteneciente al mes de enero, año 2021. Lo que representa es producto de haber combinado las bandas número 2, 3, 4, 5, 6 y 7 de la imagen. Para una visualización apreciable, la elección y configuración del orden de las bandas, a colores del espectro visible fue: banda 5 en color rojo (R), la banda 4 en color verde (G) y la banda 3 en color azul (B). Esta combinación de bandas tiene buena sensibilidad a la vegetación verde (la cual aparecerá representada en una tonalidad roja)



1:120.000



A la izquierda, una imagen stack-layer multi-temporal representando la reflectancia captada por el mismo instrumento espacial, durante el periodo comprendido entre octubre del 2020 y abril 2021. Este producto resulta de combinar (apilar) en una única imagen, la información contenida en 9 imágenes que expresan la reflectancia de la superficie terrestre en 9 días distintos, dentro del semestre detallado. Al igual que la imagen temporal posee un renderizado de las bandas número 3, 4 y 5 para el día 20 de octubre, y la composición en colores visibles RGB=5-4-3

Figura 5. Diferencias entre una imagen multitemporal vs una de fecha única.

Las imágenes Landsat 8 OLI disponibles para el área y rango temporal en estudio se enlistan en la Tabla 2, ordenadas numéricamente con su satélite, fecha de adquisición, nubosidad, bandas, resolución y path/row (fila/columna).

Tabla 2: Imágenes Landsat 8 OLI descargadas

N°	Satelite	Adquisición	Nubosidad Máx admitida	Bandas	Resolución espacial	Path/Row
1	Landsat 8 OLI T1	30-10-2020	20%	2-7	30m	227/085
2	Landsat 8 OLI T1	15-11-2020	20%	2-7	30m	227/085
3	Landsat 8 OLI T1	01-12-2020	20%	2-7	30m	227/085
4	Landsat 8 OLI T1	17-12-2020	20%	2-7	30m	227/085
5	Landsat 8 OLI T1	02-01-2021	20%	2-7	30m	227/085
6	Landsat 8 OLI T1	18-01-2021	20%	2-7	30m	227/085
7	Landsat 8 OLI T1	03-02-2021	20%	2-7	30m	227/085
8	Landsat 8 OLI T1	07-03-2021	20%	2-7	30m	227/085
9	Landsat 8 OLI T1	23-03-2021	20%	2-7	30m	227/085

Clasificación supervisada multitemporal

El producto final de una clasificación supervisada sobre imagen satelital en entorno GIS es un mapa, que por áreas situadas en coordenadas conocidas y por colores configurados a gusto, describe la representación de ocupación de clases de coberturas terrestres presentes en un tiempo y en un espacio dado.

Durante el procesamiento se ensayaron varias clasificaciones conjugando distintas cantidades de regiones de interés y los 3 algoritmos posibles de ejecutar que ofrece el software SCP (máxima verosimilitud, mapeo de ángulo espectral y distancia mínima). En anexos se podrán comparar algunos de ellos (Figuras 12 a 17).

La practicidad del Semi-automatic Classification plugin permite al usuario previsualizar lo que será el producto final de la clasificación, en función de los parámetros mencionados. Por análisis de interpretación visual y superponiendo la

verdad de campo, se optó por utilizar el algoritmo distancia mínima para la clasificación supervisada de esta tesis, debido al resultado que ofreció frente a las opciones restantes. Los resultados precisión global e índice Kappa respaldaron la elección.

En la Figura 6 queda visualmente presentado el producto central de esta tesis. Sobre la paleta de colores se puede ver e interpretar visualmente una heterogeneidad intra lote, que para la verdadera situación convencional y productiva a campo, no es ciertamente el escenario más representativo. Y la recorrida a campo aclara la situación: en el presente contexto hasta aquí descrito, el resultado de esta clasificación, no es precisamente estricto definiendo las clases de coberturas, por lo menos en la situación intra lote.

Mapa resultado de la clasificación supervisada multi-temporal de 9 imágenes satelitales Landsat 8 pertenecientes al periodo productivo estival entre los años 2020-2021, geo-referenciadas sobre el Partido de Pehuajó, Provincia de Buenos Aires.

En el entorno de los sistemas de información geográficos, se utilizó la herramienta complemento Semi-Automatic Classification Plugin para conocer y estimar las coberturas y usos del suelo sobre una fracción de tierra de 22 mil hectáreas aproximadas, a partir de datos relevados en el terreno en el periodo estival indicado. Aunque es evidente que el algoritmo de clasificación confunde firmas espectrales entre las clases de coberturas, el resultado avalado por medidas estadísticas de precisión global e índice Kappa fue 65% y 60% respectivamente, interpretándose ambos como: bueno (60%-80%), de muy bueno (80%-100%)




Figura 6: Clasificación supervisada multitemporal.

Validación de la clasificación supervisada

El resultado reflejado de la validación de la clasificación a través de la matriz de confusión arrojó un índice de precisión global de 65% aproximadamente y un Índice Kappa de 0,6. Para la escala de valoración sobre índice Kappa de Monserud y Leemans (1992), el rango de resultado 55-70% se interpreta como: Bueno. Se podría afirmar que se obtuvo un buen resultado de la clasificación, es decir, hubo un buen acuerdo entre la imagen clasificada y lo que realmente se encuentra ocupando el suelo en el área de trabajo.

La validación es resultado del cruzamiento de sitios definidos sobre la verdad de campo con los mismos sitios referidos a la imagen de la clasificación supervisada, definida con detalle en Postprocesamiento. Como representación de la realidad de campo, se utilizó la capa verdad de campo sobre la cual arrojar los puntos al azar para luego ser contrastados frente a la clasificación. De lo detallado en Postprocesamiento (Métodos), la calculadora de muestras dio como resultado que se debían tomar 384 puntos de muestreos en función de los parámetros descritos. Resultado que se decidió duplicar por recomendación de otros trabajos a un número final de 768 puntos de muestreos, para ser diseminados al azar sobre la mitad del terreno conocido como verdad de campo. Para una mejor racionalización de los resultados y en función de la ocupación en superficie de cada una de las clases, es que se practicó una ponderación. La figura 7 muestra cuántos puntos le corresponden a cada clase sobre la base de 768 puntos totales a ser validados frente a la realidad del campo.

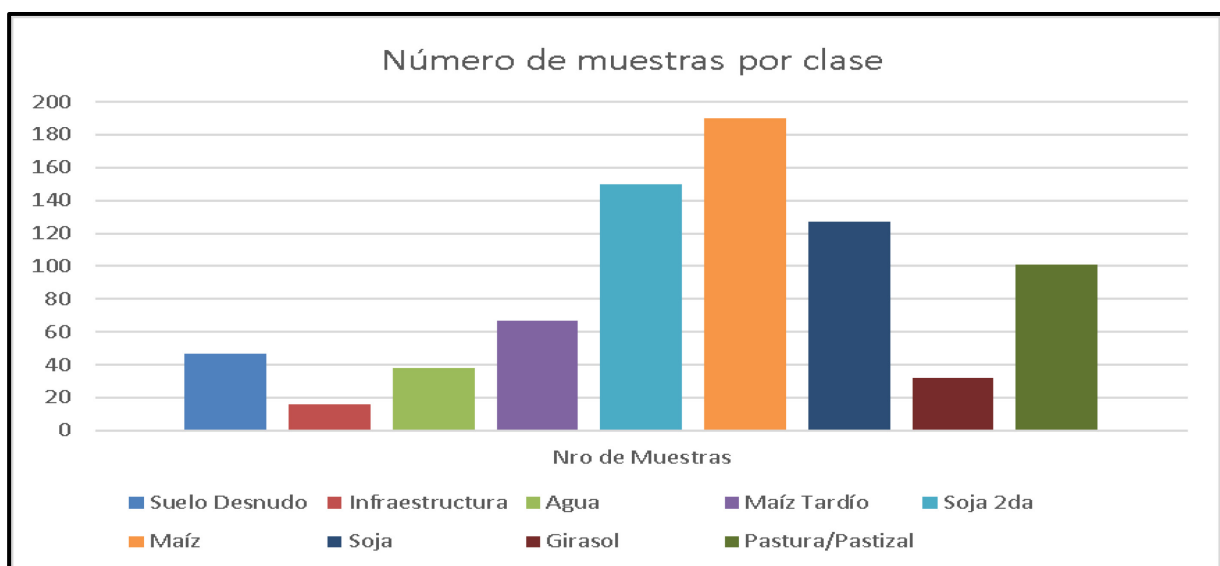


Figura 7: Cantidad de puntos de muestreos tomados por clase.

En la Figura 8 queda asentada de manera esquemática la forma que encontraron los tesisistas para cruzar los puntos al azar a ser evaluados frente a la clasificación mediante la herramienta del plugin SCP llamada Precisión (dentro de postprocesamiento). Se puede apreciar que, mediante manipulación de vectores, tabla de atributos y herramientas de investigación (Vectorial) de Qgis se pueden crear los escenarios necesarios tanto sea para entrenar al complemento SCP como para realizar la validación de la clasificación.

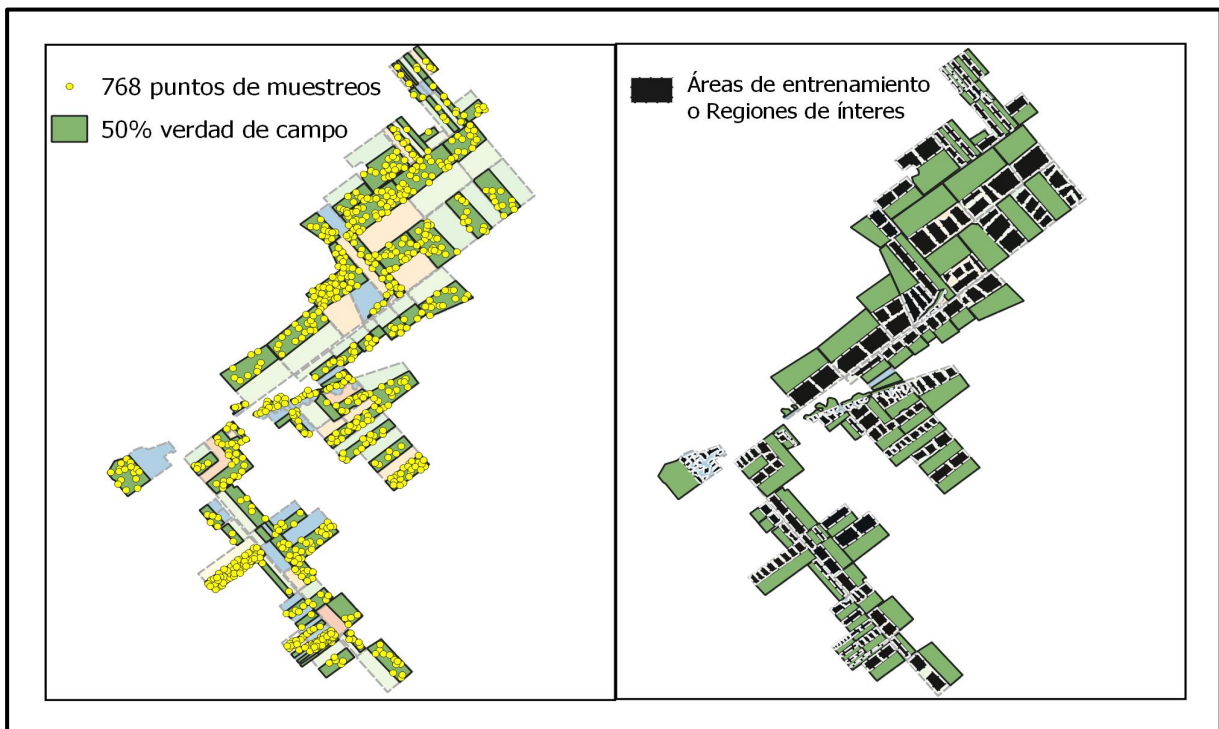


Figura 8: Imagen izquierda puntos de muestreo. Imagen derecha regiones de interés.

Usos del suelo en el área de trabajo

El reporte de la clasificación expresó las superficies obtenidas de cada una de las clases, (Tabla 3, ver en anexos), las mismas reflejan el área de ocupación que representan los píxeles agrupados en cada una de ellas, definidas para el área de trabajo. De un total de 22.767 hectáreas aproximadamente, el mayor porcentaje está constituido por maíz, soja de segunda y soja de primera, con un total aproximado del

60% de la superficie. En menores porcentajes se encuentra maíz tardío, pasturas/pastizales, girasol y suelo desnudo.

Es oportuno mencionar que la clase agua, representante de los bañados y bajos, se mostró con un porcentaje interesante, representando el 4,5% del área de trabajo, lo que se condice con lo que históricamente caracterizó a la zona, debido a su baja pendiente y problemas de escurrimiento.

La clase que menos se manifestó fue infraestructura, con un 2% de representación sobre el total, lo que se supondría erróneo ya que representaría 475 hectáreas en infraestructura, sabiendo que el poblado cuenta con alrededor de 100 hectáreas, se catalogó como una sobrevaloración para la clase, respecto de la realidad.

Teniendo en cuenta los resultados obtenidos y contabilizando las superficies devueltas por el reporte, se destaca una gran presencia de la agricultura por sobre la ganadería, esta última suma solamente el 13% aproximadamente de la superficie relevada frente a un 75% de la agricultura. Se debe tener en cuenta que las superficies son estimativas dado a que están sujetas al error propio del algoritmo y del proceso de clasificación, descrito en Post-procesamiento.




Figura 9: Expresa gráfica y visualmente el porcentaje ocupado por cada clase.

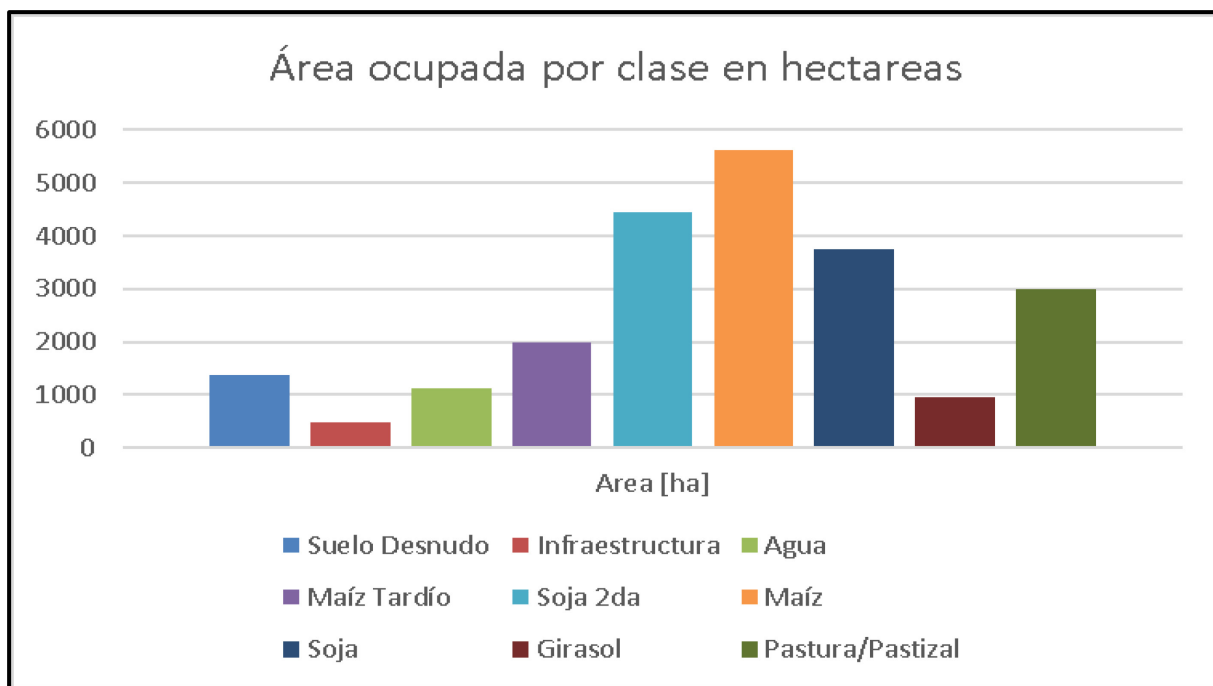


Figura 10: Expresa gráficamente el área ocupada por cada clase.

La información del reporte de la clasificación concuerda con los datos bibliográficos recopilados en el sitio web del Ministerio de Agricultura Ganadería y Pesca de La Nación debido a que los cultivos que más se practican en la zona Oeste de la provincia de Buenos Aires, más precisamente en el partido de Pehuajó, son los mismos que se expresaron y se encontraron en mayor representación dentro del área de trabajo, comprendidos éstos por los mencionados en el párrafo anterior.

Se observó y comprobó que para el año agrícola-ganadero estudiado se invirtieron los usos del suelo en cuanto a la cantidad de superficie destinada a los cultivos vegetales, ya que, en los últimos diez años el cultivo más sembrado fue soja de primera, seguido de maíz, soja de segunda y por último girasol. Es decir que en la temporada 2020/2021 los productores agropecuarios zonales, establecieron más conveniente la siembra de maíz por sobre el cultivo de soja, dato interesante a la hora de pensar en la calidad y cantidad de materia orgánica (carbono principalmente) que aportan las gramíneas frente a las leguminosas en su postcosecha, y cómo esto repercute en la estructuración de los suelos, más aun recordando los suelos zonales, Hapludoles, caracterizados por susceptibilidad a erosión eólica e hídrica.

Clasificación multitemporal vs fecha única

Es sabido que de una clasificación supervisada multitemporal se obtienen mejores resultados estadísticos que de una clasificación hecha a partir de una sola imagen, debido a que la clasificación de un suelo agrícola presenta particularidades por la heterogeneidad debida no sólo a los distintos cultivos, sino también a diferentes fechas de siembra, estado fenológico, tecnología utilizada, etc. En este sentido, Marini *et al.* (2007) y Murthy *et al.* (2003) han encontrado que la máxima discriminación entre los cultivos ocurre en diferentes etapas del crecimiento y por lo tanto no es posible la captura de esas diferencias usando la imagen de una sola fecha. En consecuencia, el empleo de datos multitemporales, que proporcionan información adicional sobre la fenología de la vegetación, ha sido recomendado para mejorar la discriminación. Aun así, luego de reiteradas discusiones entre los tesisistas analizando la bibliografía, surgió la necesidad de corroborar, mediante práctica propia, la conveniencia o no de trabajar una clasificación multitemporal a partir de una base de datos espectrales contenidos en 9 imágenes satelitales, capturadas a lo largo de 6 meses, contra trabajar una clasificación sobre una fecha única, sobre una base de datos de una sola imagen satelital, que captura la energía reflejada terrestre de un solo día. La conveniencia o no, pone en tela de discusión, si el trabajo y el tiempo dedicado a procesar información de un semestre, justifica la calidad y validez de la clasificación obtenida frente a una clasificación de fecha única.

Los resultados obtenidos después de aplicar la metodología de clasificación supervisada dan cuenta que la imagen stack-layer multitemporal presenta los mayores valores de validación en los índices estadísticos de precisión global e índice Kappa. En la serie multitemporal la presencia de mayor cantidad de datos que incluyen a los cultivos en sus distintas etapas de desarrollo y datos del rastrojo precedente, permite decididamente una mejor clasificación. En el análisis comparativo se estableció más conveniente la realización de una clasificación multitemporal, respaldado esto por los resultados obtenidos de ambas clasificaciones y la bibliografía estudiada, que son expresados a continuación.

Clasificación supervisada multitemporal

- Precisión global: 65%

- Índice Kappa: 0,6

Clasificación supervisada de fecha única.

- Precisión global: 58%
- Índice Kappa: 0,50

En la Figura 11 se presenta visualmente la clasificación supervisada sobre una única fecha, con sus especificaciones y referencias.

Mapa de la clasificación supervisada temporal realizada sobre la imagen Landsat 8 perteneciente al día 18 de enero del periodo productivo estival año 2021, geo-referenciada sobre el Partido de Pehuajó, Provincia de Buenos Aires.

Lo que diferencia a este producto respecto de la clasificación supervisada multi-temporal (realizada sobre un apilamiento de 9 imágenes) es la cantidad de información sobre la reflectancia de cobertura terrestre analizada, dado que se trata de una única imagen. El resto de la metodología de procesamiento (combinaciones y renderizado de imagen) es el mismo. El objetivo de la comparación entre la multi-temporalidad vs. la temporalidad de fecha única fue evaluar calidad de productos obtenidos. El resultado fue: una clara discrepancia visual en lo que respecta al reconocimiento de las clases de coberturas, respaldado por las medidas estadísticas de precisión global e índice Kappa, con valores de 58 % y 50% respectivamente.




Figura 11: Clasificación supervisada sobre una fecha única, 18 de enero de 2021.

Eventos agroclimáticos destacables

Se registró un año climático ordinario con lo que respecta a los datos históricos recopilados y estudiados para lluvias y temperaturas. No así para eventos agroclimáticos desfavorables como la caída de granizo, en el mes de febrero del año 2021 se registró un siniestro, lo que perjudicó el desarrollo de una parte de los cultivos que se encontraban implantados, se estima que puede haber afectado en el resultado de la clasificación supervisada.

Ventajas y desventajas sobre las distintas vías de descarga de imágenes satelitales

Para las descargas de imágenes satelitales se estudió y practicó la conveniencia de dos caminos para su obtención gratuita. El primero directamente de la plataforma oficial del Servicio Geológico de los Estados Unidos y el segundo con el software Qgis a través del complemento SCP. Para ambos casos primero se debe contar con una cuenta en el servicio geológico de Estados Unidos. Aunque desde Qgis, el camino a recorrer es más corto y sencillo, el servidor suele tener demoras y problemas de conexión, programación, lo que podría eventualmente imposibilitar el correcto funcionamiento y obtención de productos.

En concordancia con lo expresado en el párrafo anterior, las imágenes utilizadas fueron descargadas desde la plataforma del servicio geológico directamente.

CONCLUSIONES

En función de los resultados obtenidos se concluye que las imágenes Landsat resultan un recurso poderoso para la determinación de las distintas coberturas y usos del suelo a gran escala mediante clasificaciones supervisadas.

Por otro lado, y desde la utilidad que prestan los SIG e imágenes satelitales, resultó valorable y oportuno analizar la importancia de estas herramientas e insumos, que son accesibles sin mayores dificultades, y por sobre todo de libre acceso, destacando que se puede generar esta fuente de información con resultados confiables desde un escritorio y con un computador.

Aumentar el número de polígonos de entrenamiento (y que los mismos sean proporcionados entre ellos) mejora la calidad de la clasificación. De igual manera, aumentar la superficie de la verdad de campo y equiparar la cantidad de esas superficies relevadas.

Mediante la manipulación de vectores, tabla de atributos y herramientas de investigación (Vectorial) de Qgis se pueden crear los escenarios necesarios tanto sea para entrenar al complemento SCP como para realizar la validación de la clasificación.

El análisis de una serie multitemporal de imágenes Landsat permite buena precisión al clasificar distintas clases de cobertura del suelo agrícola. Utilizar una serie multitemporal integrada supera en eficiencia a las clasificaciones individuales realizadas con datos de una sola escena, logrando una buena identificación de los principales cultivos implantados de la zona. Si se dispone sólo de imágenes de fechas individuales el algoritmo clasificador pierde capacidad de discriminación entre cultivos tempranos y tardíos, cuando los mismos se encuentran en diferentes etapas de su desarrollo.

Toda clasificación supervisada tiene errores propios del proceso, se aconseja realizar la validación de la misma. Esto es determinante a la hora de analizar resultados obtenidos, precisión global e índice Kappa fueron los en este trabajo y son recomendados, por los tesisistas y por la bibliografía consultada para trabajos similares.

Con un bajo porcentaje de datos bien relevados a campo, sumado a una buena práctica e interpretación de las herramientas de procesamiento como de post procesamiento se pueden obtener resultados confiables para respaldarse en la aplicabilidad de la herramienta. Es primordial seguir un orden metodológico tanto en el trabajo de campo como en el de gabinete para lograr los objetivos que se planteen.

La mejor vía de descarga de las imágenes satelitales resultó ser mediante la plataforma del servicio geológico de Estados Unidos, debido a que presenta mayor estabilidad, rapidez y un entorno más intuitivo en comparación con las otras, lo que la hace recomendable para el nivel de procesamiento utilizado.

Atravesar el proceso de realizar un trabajo final de carrera es un gran desafío para un estudiante de las ciencias agrarias y forestales, conlleva una asociación de muchos de los conceptos adquiridos a lo largo de los años de cursada y a su vez ganar nuevas habilidades a la hora de poner en práctica el uso de estas herramientas que demuestran tener una gran utilidad. Descubrir que aprender el proceso es más útil que cualquier herramienta en sí, fue lo más destacable para los tesisistas, habiendo concluido el presente trabajo.

BIBLIOGRAFÍA

-¿Qué son los **Sistemas de Información Geográfica (SIG)**? Disponible en: <https://geoinnova.org/cursos/que-son-los-sistemas-de-informacion-geografica-sig/>

Último acceso: 4/4/2022.

-**Boca. INTA. Instituto de clima y agua, Castelar. (s.f.)**. Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos.

-**Burkart, S.; Leon, R.; Conde, M y Perelman, S. 2010**. Diversidad de especies de plantas en praderas remanente en suelos arables en La Pampa de cultivo. Editorial Facultad de Agronomía, UBA, Buenos Aires, Argentina.

-**Cartas de Suelos de la República Argentina, INTA. 2013**. Disponible en: <http://www.geointa.inta.gob.ar/2013/05/26/suelos-de-la-republica-argentina/> Ultimo acceso enero de 2021.

-**Catálogo ScienceBase, Instalación de cobertura terrestre global**. Disponible en <https://www.sciencebase.gov/catalog> Ultimo acceso: 5/02/2021.

-**Chuvieco, E. 1995**. Fundamentos de la teledetección espacial. Ediciones Rialp, S.A, segunda edición. Pp. 41.

-**Congedo, Luca. 2021**. Complemento de clasificación semiautomática: una herramienta de Python para la descarga y el procesamiento de imágenes de detección remota en QGIS. Revista de software de código abierto, 6(64), 3172, <https://doi.org/10.21105/joss.03172>

-**Control estricto de matrices de confusión por medio de distribuciones multinomiales. 2018**. Disponible en: <file:///C:/Users/Usuario/Downloads/Dialnet-ControlEstrictoDeMatricesDeConfusionPorMedioDeDist-6522539.pdf>

-**Di Leo. 2015**. Drones: nueva dimensión de la teledetección agroambiental y nuevo paradigma para la agricultura de precisión. Agromensajes Vol. 41. Pp 7-17

-**El satélite Landsat 8: imágenes, descripción y características**: Disponible en: <https://eos.com/es/find-satellite/landsat-8/>

-**Gantz, J. 1990**. GIS Meets GPS. Computer Graphics World, October 1990, pp 33-36

- García Ferrer-Porras, A. 2013.** Potencialidad y nuevas orientaciones en el uso de la teledetección en agricultura y selvicultura. *Ambienta* Vol. 105. Pp 6-15.
- INTA. Estación experimental agropecuaria General Villegas.** Memoria técnica 2009-2010.
- Lang, L. & V. Speed. 1990.** A New Tool for GIS. *Computer Graphics World*, October 1990, Pp 41-48.
- Marini, M. F., Vergara, M. F., Krüfer, H. 2007** Determinación del uso de la tierra en el partido de Guamini (Argentina) mediante un estudio multi-temporal con imágenes Landsat. *Revista de Teledetección* Vol.27 Pp.80-88.
- Ministerio de Agricultura, Ganadería y Pesca. 2020.** Disponible en: <https://datos.magyp.gob.ar/dataset> Último acceso: noviembre de 2020.
- Ministerio de agroindustria. 2015.** Caracterización de la producción bovina.
- Monserud, R.A., Leemans, R. 1992** Comparing Global Vegetation Maps with the Kappa Statistic. *Ecological Modelling* Vol.62 Pp.275-293.
- Municipalidad de Pehuajó, 2020.** Disponible en: http://www.pehuajo.gob.ar/p/la-ciudad_27.html Último acceso: Enero 2021.
- Murthy, C. S., Raju, P.V., Badrinath, K.S. 2003** Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks. *International Journal of Remote Sensing* Vol.24 Pp4871- 4890.
- Nocelli. 2017.** Manejo del planteo nutricional y reproductivo en un sistema de cría bovina en el partido de Pehuajó.
- Portillo, J. 2017.** Monitoreo de cultivos utilizando datos de teledetección y modelos de crecimiento. *Rta* Vol. 10, número 34.
- Pueyo Campos, A. 1991.** El sistema de información geográfica: un sistema para la planificación y gestión urbana. *Geographicalia* Vol. 28. Pp 175-192.
- QGIS - El SIG Líder de Código Abierto para Escritorio.** Disponible en: <https://qgis.org/es/site/about/index.html> Último acceso: 11/4/2022.
- Salcido, R. 2018.** Investigación sobre recién egresados con empleo en la Facultad de Ciencias Políticas y Sociales. Universidad Autónoma de Chihuahua.

-Sensores Remotos UNNE, 2021. Matriz de confusión. Youtube.
<https://www.youtube.com/watch?v=69MyTNA8Nyw&t=690s>

-USGS science for a changing world Disponible en:
<https://www.usgs.gov/search?keywords=como+citar+la+pagina>

ANEXOS

Tabla 1: Los cultivos agrícolas más practicados en Partido de Pehuajó. Promedio de datos relevados entre los años 2010 y 2020. (Fuente: elaboración propia en base a MAGyP)

	Sup. Sembrada (ha)	Rendimiento (Kgr/ha)
Cebada	9.897	4.000
Centeno	2.675	2.112
Trigo total	30.334	3.736
Girasol	8.345	2.439
Maíz	64.928	7.990
Soja 1ra	116.371	3.191
Soja 2da	37.469	2.255
Sorgo	2.197	5.709

Tabla 3: Reporte de la clasificación supervisada multitemporal

Clase	PixelSum	Porcentaje %	Area [ha]	Clases	Nro de Muestras
1	15412	6,094	1387,524	Suelo Desnudo	47
2	5283	2,089	475,622259	Infraestructura	16
3	12593	4,979	1133,733	Agua	38
4	21938	8,674	1975,052	Maíz Tardío	67
5	49371	19,522	4444,813	Soja 2da	150
6	62478	24,705	5624,821	Maíz	190
7	41711	16,493	3755,192	Soja	127
8	10638	4,206	957,727	Girasol	32
9	33369	13,195	3004,172	Pastura/Pastizal	101
TOTAL	252.890,00	100	22.767,39		768




Figura 12: Mapeo de ángulo espectral con 15 regiones de interés por clase.




Figura 13: Máxima verosimilitud con 15 regiones de interés por clase.




Figura 14: Distancia mínima con 15 regiones de interés por clase.




Figura 15: Mapeo de ángulo espectral con 3 regiones de interés por clase.




Figura 16: Máxima verosimilitud con 3 regiones de interés por clase.




Figura 17: Distancia mínima con 3 regiones de interés por clase.

Tabla 4: Longitudes de onda en el espectro electro-magnético para las bandas utilizadas en el procesamiento de imagen.

	Bandas	Longitud de onda (en micrómetros)	Resolución (en metros)
Landsat 8 Operational Land Imager (OLI)	Banda 2-Azul	0.45-0.51	30
	Banda 3-Verde	0.53-0.59	30
	Banda 4-Rojo	0.64-0.67	30
	Banda 5-Infrarrojo cercano (NIR)	0.85-0.88	30
	Banda 6-SWIR (1)	1.57-1.65	30
	Banda 7-SWIR (2)	2.11-2.29	30