Universidad de la República

Tecnólogo en Cartografía

PRECISIÓN Y EXACTITUD DE LA BANDA ESPECTRAL Red-Edge APLICADO A LA DETECCIÓN Y MONITOREO DEL BOSQUE NATIVO EN URUGUAY

Estudiantes: Damián Sampayo; Ignacio Vinçón.

Tutores: Ing. Agrim. Edison Rosas; Ing. Agrim. Hebenor Bermúdez.

MONTEVIDEO

URUGUAY

2018

Contenido

1 INTRODUCCIÓN 2
2 OBJETIVOS 3
2.1 Objetivo General 3
2.2 Objetivos Específicos 3
3 MARCO TEÓRICO 4
3.1 Área de estudio 4
3.2 Especies invasoras 4
3.3 Teledetección. 6
3.4 Región Espectral Red-Edge 8
3.5 Imágenes Satelitales. 8
3.5.1 Sentinel-2 8
3.5.1.1 Características Generales 8
3.5.1.2 Especificación del Producto y Corrección Atmosférica. 10
3.5.2. Landsat-8 14
3.5.2.1 Corrección Atmosférica. 14
3.5.3 Clasificación Supervisada. 15
4 METODOLOGÍA Y MATERIALES 16
4.1 Esquematización de Metodología de Estudio. 16
4.2 Selección de Área de Estudio. 16
4.3 Adquisición de Imágenes. 17
4.4 Generación de Imágenes Multibanda (corrección atmosférica, recorte y apilado de bandas) 17
4.5 Índice de Vegetación de Diferencia Normalizada (NDVI) 19
4.6 Salida de Campo 19
4.7 Validación NDVI 20
4.8 Clasificación Supervisada y Validación. 21
5 RESULTADOS Y DISCUSIÓN 23
5.1 Índice de Vegetación de Diferencia Normalizada (NDVI) 23
5.2 Clasificación Supervisada. 24
6 CONCLUSIONES 30
7 BIBLIOGRAFÍA 31
8 ANEXO 34

1 INTRODUCCIÓN

Las invasiones biológicas constituyen uno de los principales factores en la pérdida de diversidad biológica y en la alteración de la capacidad de los ecosistemas para proveer servicios ambientales (Vitousek et al. 1997). Conocer el patrón de distribución de una especie invasora resulta esencial para definir estrategias de control eficientes, visualizar la posible dinámica del proceso de invasión (Bradley & Mustard 2006; Byers et al. 2001; Rew et al.2005) y prever el potencial desarrollo del proceso invasivo. Además, permite identificar potenciales mecanismos de dispersión, así como definir la susceptibilidad de distintos tipos de hábitat al proceso de invasión (Andersen et al. 2004; Cohen & Goward 2004; Parker et al. 1999).

La necesidad de mejorar el monitoreo de la flora en sus diferentes ámbitos, nos ha llevado a plantear la propuesta de experimentar con nuevos conjuntos de datos, que hoy podemos acceder a partir del desarrollo tecnológico. En este sentido la teledetección se ha convertido en una de las herramientas más utilizadas para el estudio de la misma.

El objetivo general de este trabajo consiste en la identificación del Bosque Nativo y su degradación por especies invasoras, mediante el empleo del manejo de teledetección con productos de diferentes sensores remotos.

El estudio se ha realizado mediante el procesamiento de imágenes satelitales captadas por el sensor Sentinel 2 (en adelante S2), proveniente de la Agencia Espacial Europea. Dichas imágenes cuentan con bandas espectrales denominadas Red-Edge. Además, se han utilizado imágenes del sensor Landsat 8 (en adelante L8), que no cuentan con bandas espectrales Red-Edge, aunque de todas formas son comúnmente utilizadas para el estudio de la vegetación.

Según estudios espectrales de la vegetación realizados anteriormente, la banda espectral Red-Edge aporta información relevante acerca del estado de salud de la vegetación. Esto se debe a que, en el espectro visible, la banda espectral roja es una de las áreas donde la clorofila absorbe fuertemente la luz, mientras que, en el área perteneciente a la banda espectral del infrarrojo cercano, la estructura celular de la hoja produce una fuerte reflexión. Por lo tanto, las variaciones del contenido de clorofila, como la estructura celular de la hoja, a menudo se ven reflejadas en la banda espectral Red-Edge, ubicada entre las bandas antes mencionadas (Zaraza, 2015).

2 OBJETIVOS

2.1 OBJETIVO GENERAL

- Identificar el Bosque Nativo y su degradación por especies invasoras, a través del empleo y manejo de técnicas de teledetección mediante productos de diferentes sensores remotos.

2.2 OBJETIVOS ESPECÍFICOS

- Comprobar la utilidad de la banda Red-Edge para el análisis variacional de la vegetación.
- Comparar los resultados obtenidos utilizando el sensor S2, con los realizados mediante el uso del sensor L8.
- Generar un punto de partida, para el continuo monitoreo del área de estudio.

3 MARCO TEÓRICO

3.1 ÁREA DE ESTUDIO

El estudio se realizó en la cuenca del Santa Lucía, en la zona delimitada por las ciudades de Florida y Santa Lucía, localizándose con un sistema de coordenadas WGS84 21S UTM entre el extremo suroeste (546836,3; 6190253,5) y extremo noreste (576685,4; 6235540,6).

Esta zona se caracteriza por explotaciones agropecuarias intensivas, en las cuales se destacan los cultivos de secano, cultivos de regadío y tambos, además de contar con una amplia área de bosque nativo sobre las márgenes de los cursos hídricos.

Las lluvias en la cuenca del río Santa Lucía varían entre 1100 y 1200 mm anuales y la temperatura media anual alcanza a 17 ºC, según Dirección Nacional de Meteorología (DNM). Esta cuenca abarca una superficie de 13.310 km2 y nueve subcuencas, integradas por una vasta red fluvial, que comprende tres ríos mayores: Santa Lucía, San José, Santa Lucía Chico según Dirección General Recursos Naturales Renovables. (DGRNR)

3.2 ESPECIES INVASORAS

Presentes en los distintos ecosistemas vegetales, aparecen, tanto por debajo del dosel de los bosques como en los claros de las mismas y en zonas aledañas, incluyendo árboles, arbustos y otro tipo de vegetales.

De acuerdo a observaciones de expertos en distintos departamentos del país, a continuación, se expone un listado de las principales especies exóticas que pueden desarrollar un comportamiento invasor en los bosques naturales. (Nobel, J. P., [et al.] 2006, DGF-MGAP)

Tabla 1: Principales especies halladas en los bosques naturales del Uruguay.

Especie	**Nombre común**	**Origen**	**Categoría**
Acacia longifolia	Acacia	Australia	Impacto limitado
Ailanthus altissima	Ailanto	Asia	Impacto limitado
Cotoneaster spp.	Cotoneaster	Europa y Asia	Amplia distribución o impacto adverso
Crategus spp.	Arto de manzaneta	Hemisferio Norte	Amplia distribución o impacto adverso
Cytisus monspessulanus	Ratamilla	Europa mediterránea	Impacto limitado
Fraxinus spp.	Fresno	Hemisferio Norte	Amplia distribución o impacto adverso
Gleditsia triacanthos	Acacia de tres espinas	América del norte	Amplia distribución e impacto adverso
Ligustrum spp.	Ligustro	Asia	Amplia distribución, severo impacto, muy agresiva
Pittosporum undulatum	Pitosporo de bayas anaranjadas	America del Norte y Europa	Amplia distribución o impacto adverso
Populus alba	Álamo blanco	Europa y Asia	Amplia distribución e impacto adverso
Rubus sp	Zarza arroyera	Europa	Amplia distribución, severo impacto, muy agresiva

Elaboración Propia. Fuente: "La contaminación del bosque nativo por especies arbóreas y arbustivas exóticas"

3.3 TELEDETECCIÓN.

“Podemos definir a la Teledetección como la técnica que tiene por objeto la captura, tratamiento y análisis de imágenes digitales tomadas desde satélites artificiales.

El fenómeno de la Teledetección es posible gracias a la interacción de la energía electromagnética con las cubiertas terrestres. Éstas tienen un comportamiento refractivo variable, condicionado tanto por factores externos como por sus propias características físico químicas en el momento de la toma de la imagen.

Los manuales describen un sistema de Teledetección, como un conjunto de componentes imprescindibles que permiten aproximarnos al conocimiento de esta técnica.

El primero de estos componentes es una fuente generadora de radiación electromagnética. La energía originada por esta fuente se refleja en las distintas cubiertas terrestres, y tras atravesar la atmósfera, es recogida por sensores óptico electrónicos situados a bordo de vehículos espaciales.

Dicha información es transmitida a los Sistemas de Recepción, como una señal digital, en forma de matriz numérica. En dichos Sistemas se lleva a cabo un primer tratamiento de la imagen, gracias al cual son depurados algunos errores de índole geométrico o radiométrico antes de ser distribuida dicha imagen a los usuarios.

Por último, la imagen en formato analógico o digital es analizada por los usuarios. Éstos realizan procesos de tratamiento visual o digital, tras los cuales se obtienen unos nuevos datos que pueden cobrar forma de mapas temáticos o de tablas estadísticas que recogen el comportamiento de una determinada variable.” (C. Pérez Gutiérrez; Á. L. Muñoz Nieto, 2006)

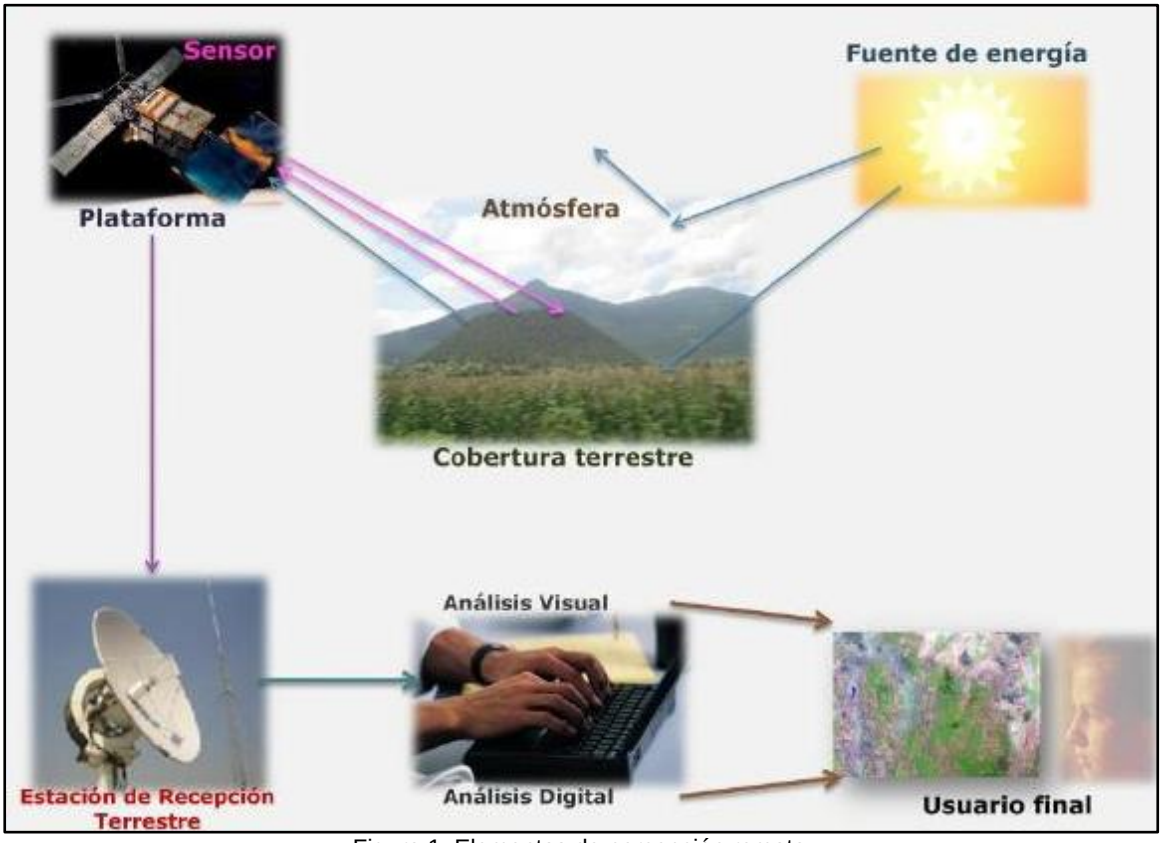

Figura 1: Elementos de percepción remota.

(Fuente:http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/img/remota2.jpg)

“La superficie de nuestro planeta, de modo global, se considera dividida en tres grandes tipos de cubiertas: superficies con agua, superficies con vegetación y suelos. Cada una de esas cubiertas encierra múltiples situaciones individuales distintas.

Para cada cubierta, el comportamiento espectral, es decir, la forma de reflejar la energía en las distintas longitudes de onda, no es único y homogéneo, sino que varía sustancialmente en función de los siguientes factores:

- Físicos (temperatura, humedad o textura).
- Químicos (composición, contenido de materia orgánica, etc.).
- Ambientales (pendiente, orientación, estación del año, hora de la toma, etc.).

En el momento actual de desarrollo tecnológico, los sensores espaciales utilizan un ámbito reducido de longitudes de onda que van desde el espectro visible, comprendido entre 400 y 700 nanómetros, hasta el dominio de las microondas, pasando, en un emplazamiento intermedio, por las regiones espectrales del infrarrojo.

La imagen es capturada a bordo del satélite mediante una serie de detectores fotoeléctricos que transforman los niveles de radiancia, procedentes de la superficie terrestre, en valores numéricos que se denominan niveles digitales. El valor del nivel digital de un píxel es proporcional a la intensidad de radiancia procedente del terreno.

El procedimiento de formación de la imagen digital se repite para cada una de las bandas generando como resultado final una matriz tridimensional en la que el valor del nivel digital de cada píxel está ubicado en una fila, una columna y una banda. Por este procedimiento es que se denominan a las imágenes como multiespectrales.” (C. Pérez Gutiérrez; Á. L. Muñoz Nieto, 2006)

Los sistemas de sensores de Teledetección poseen cinco resoluciones:

- *Espacial:* es el tamaño del objeto más pequeño que puede ser distinguido en una imagen (tamaño del píxel sobre el terreno).
- *Radiométrica:* es la capacidad del sensor para discriminar niveles o intensidades de radiancia. A mayor número de bits reservados para almacenar el valor de la reflectividad de un píxel, mayor resolución radiométrica.
- *Espectral:* indica el número de anchura de las bandas espectrales que puede discriminar el sensor. Un sensor tendrá una resolución espectral más grande cuanto mayor sea el número de bandas que proporcione.
- *Temporal:* indica el tiempo de paso del satélite sobre la vertical de un punto; con ello se determina la periodicidad de adquisición de imágenes de una misma zona. Cuantifica la capacidad que tiene un sistema sensor para registrar los cambios temporales acaecidos sobre una determinada zona. Es de suma importancia para abordar estudios evolutivos.
- *Angular:* la capacidad que tiene un sensor para tomar imágenes oblicuas. Esta propiedad permite no solamente acortar los ciclos temporales de recubrimiento, sino que posibilita la generación de imágenes estereoscópicas y por lo tanto la reconstrucción del relieve.

3.4 REGION ESPECTRAL RED-EDGE

La relevancia de la región espectral Red-Edge para la caracterización de la vegetación ha sido reconocida desde hace muchos años. Varios estudios han sugerido que la transición entre la absorbancia de color rojo y el infrarrojo cercano es capaz de proporcionar información adicional sobre la vegetación y sus características.

La región del Red-Edge corresponde a una sección del espectro electromagnético que se ubica en la transición de la banda del rojo a la banda del infrarrojo cercano (NIR) por lo que termina ocurriendo entre 680 y 750 nanómetros (nm), donde la reflectancia cambia de muy bajo en la absorción de la banda del rojo y por la clorofila a muy alto en el infrarrojo cercano por la hoja y la cubierta de ésta. Varios estudios han podido determinar que el contenido de clorofila es el componente que mejor se correlaciona con la longitud de onda de esta banda, mientras que el índice de área foliar (LAI) se halla más en relación a la amplitud y área del mismo. (Zaraza, 2015)

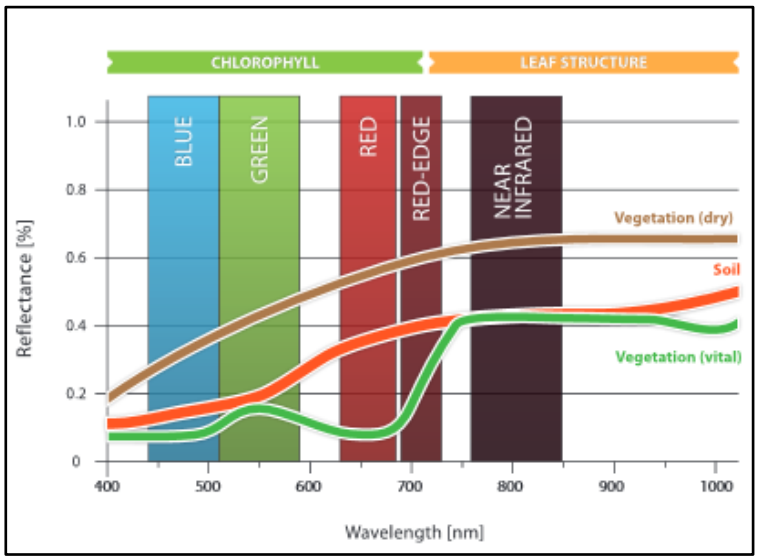

Figura 2: Sensibilidad de reflectancia en la banda Red Edge según la vegetación, (Fuente: BlackBridge.org).

3.5 IMÁGENES SATELITALES.

3.5.1 Sentinel-2

3.5.1.1 Características Generales

El reciente lanzamiento del satélite S2 de la ESA (European Space Agency), ha despertado un gran interés en la comunidad científica debido a sus múltiples aplicaciones, pues su resolución espacial, temporal, espectral y radiométrica y su distribución gratuita abren una nueva era en la observación de la Tierra.

Las imágenes proporcionadas por ESA-2016, han mejorado los servicios de datos multiespectrales disponibles hasta el momento dentro del programa europeo GMES (Global Monitoring Environmental and Security).

Lo que refiere a resolución temporal, la misión cuenta con doble nave espacial a bordo: Sentinel-2A y Sentinel-2B, que proporcionan una cobertura global cada 10 días, sin embargo, el doble sensoramiento al pertenecer a la misma órbita, posee la ventaja de reducir la frecuencia del ciclo de revisión a 5 días.

Para la captura de los datos, la constelación utiliza un sistema de barrido a lo largo de la trayectoria denominado push-broom[1], generando imágenes de 290 Km de ancho y así poder ofrecer muy altas prestaciones geométricas y espectrales en sus datos. Además, están equipados con instrumental de última generación MSI "*Multispectral Imager*", que ofrece productos ópticos de alta resolución espectral y radiométricos, teniendo como objetivo medir la radiancia reflejada de la tierra a través de la atmósfera. La cámara cuenta con dos grandes planos focales, uno en las bandas del visible (RGB) y del infrarrojo próximo (VNIR), y el otro en el infrarrojo medio (SWIR). Equipados cada uno de ellos con una matriz de 12 detectores con un total de 450.000 píxeles en el rango del espectro antes mencionado.

Los datos de radiancia captados por los detectores son almacenados en 13 bandas espectrales. Cuatro de sus bandas tendrán una resolución espacial de 10 metros, seis a 20 metros y tres a 60 metros, que aportan una nueva perspectiva de la superficie terrestre y su vegetación.

La particularidad de estos conjuntos de datos, es que S2 incorpora tres nuevas bandas en la región del Red-Edge que mejora la configuración del sensor para estudios de aguas y vegetación (Delegido et al., 2011).

La región del espectro Red-Edge, Borde del rojo, es capaz de captar la variación clorofílica de la vegetación, en este caso ubicándose en las bandas b5, b6 y b7 propias de este sensor.

La tabla a continuación muestra la correspondencia entre el número entero de bandas y su resolución espacial y radiométrica de un producto S2.

[1] Conjunto de filas de sensores formando una matriz haciendo la captura de la información a medida que avanza el satélite.

Tabla 2. Distribución espectral para cada banda.

Banda	Id_Banda	Resolución espacial	Centro de longitud de onda (nm)
B1	1	60	443
B2	2	10	490
B3	3	10	560
B4	4	10	665
B5	5	20	705
B6	6	20	740
B7	7	20	783
B8	8	10	842
B8a	9	20	865
B9	10	60	945
B10	11	60	1375
B11	12	20	1610
B12	13	20	2190

Fuente: Elaboración propia. Extraído de "Sentinel-2-Product-Specifications-Document"

3.5.1.2 Especificación del Producto y Corrección Atmosférica.

Cuando se desea acceder al producto S2 es necesario dirigirse a la plataforma web https://scihub.copernicus.eu/dhus/#/home. donde se podrán descargar de forma gratuita los productos de preferencia 1B y 1C para luego de procesado conseguir un producto 2A.

Los distintos niveles presentan las siguientes categorías:

- Nivel 1B: este producto contiene datos de la parte superior de las radiaciones de la atmósfera, teniendo un volumen de información de 27 MB.
- Nivel 1C: producto de reflectancia de la parte superior de la atmósfera (en adelante TOA) georreferenciadas en sistema de referencia y proyección WGS84 y UTM respectivamente, conteniendo correcciones radiométricas y geométricas incluida una ortorectificación.

- Nivel 2A: para acceder a este nivel es necesario procesar la imagen en el software SNAP[2] con la caja de herramientas propia de S2 de ESA y así adquirir la herramienta Sen2Cor (Sentinel 2 Corrections). Esta se basa en un conjunto de técnicas para la corrección atmosférica y un módulo de clasificación de escena (ESA, 2016), el resultado es un producto de reflectividades al borde de la atmósfera (en adelante BOA), correspondiente al nivel 2A, además de un mapa de espesor óptico de aerosoles, un mapa de vapor de agua y un mapa de clasificación de la escena junto con los indicadores de calidad. (Borràs et al., 2017).

El modelo atmosférico de Sen2Cor depende del cálculo de las funciones de transferencia radiactiva para diferentes geometrías solares y sensores, elevaciones del suelo y parámetros atmosféricos, basadas Look Up Tables (tabla de búsqueda), el procesador lee el parámetro en forma de Look Up Tables (LUT) perteneciente a este espacio de parámetros e interpola, si es necesario. Los LUT tienen generado a través de libRadtran[3], una biblioteca para el cálculo de energía solar y térmica (ESA, 2016).

El producto 1C es distribuido a los usuarios por defecto como SENTINEL - SAFE (Sentinel - Standard Archive Format for Europe). Los archivos SAFE fueron diseñados para actuar como un formato común para el archivo de datos dentro de las instalaciones de observación de la ESA y para la distribución de datos a los usuarios finales. Esta extensión cumple con el modelo de referencia ISO 14721: 20033[4] OAIS (Open Archival Information System) y estándares relacionados como la emergente CCSDS / ISO XFDU[5] (unidades de datos con formato XML).

El usuario tendrá la posibilidad de seleccionar otro formato de salida opcional basado en DIMAP (MAP de imagen digital-2). Estos formatos son ideales para transportar grandes volúmenes de geodatos. Finalmente, es importante tener en cuenta que Sentinel-2 cumple con INSPIRE (Infraestructura para la información espacial en la Comunidad Europea) regulación de metadatos de información espacial o geográfica para que sea más accesible e interoperable en una amplia gama de propósitos.

Los archivos SAFE se subdividen en varias carpetas, tema que escapa a los fines de este estudio, sin embargo, una de ellas contiene los datos comprimidos de imágenes y sus conjuntos de datos, uno por cada banda (ver Figura 3), usando el formato JEPG2000 compatible y de fácil lectura por el software SNAP. Esta última es una plataforma de aplicaciones Sentinel de la ESA, con una arquitectura de código abierto de fácil y gratuita instalación y herramientas ideales para la explotación de datos de observación de la Tierra. Para generar el producto 2A entonces, es necesario instalar el complemento Sen2Cor como ya se mencionó anteriormente. Esta herramienta proporcionada por la ESA, genera producto 2A basado estrictamente en la estructura del producto 1C con algunas diferencias. La principal diferencia que presenta es la carpeta IMG_DATA (ver Figura 4) contiene tres nuevos directorios, además de los recuadros verdes (Jérôme et al.), que fueron creados a partir del total de bandas seleccionadas o por la elección del usuario, uno para cada resolución a 60m, 20m y 10m.

[2] Software diseñado para el procesamiento y análisis de observaciones de la tierra.

[3] Biblioteca para transferencia radiactiva, es una colección de funciones y programas C++ y Fortran para el cálculo de la radiación solar y térmica en la atmósfera de la Tierra. libRadtran está disponible gratuitamente bajo la Licencia Pública General de GNU.

[4] Especifica un modelo de referencia para un sistema abierto de información de archivo (OAIS). El objetivo es establecer un sistema para archivar información, tanto digitalizada como física, con un esquema organizativo compuesto por personas que aceptan la responsabilidad de preservar la información y ponerla a disposición de una comunidad designada.

[5] Los estándares CCSDS también disponibles en estándares ISO, son para sistemas de datos y comunicaciones relacionados con el espacio. Estas son normas acordadas internacionalmente que reducen los costos operativos y los riesgos, y brindan interoperabilidad y capacidades innovadoras para las misiones actuales y futuras de la NASA.

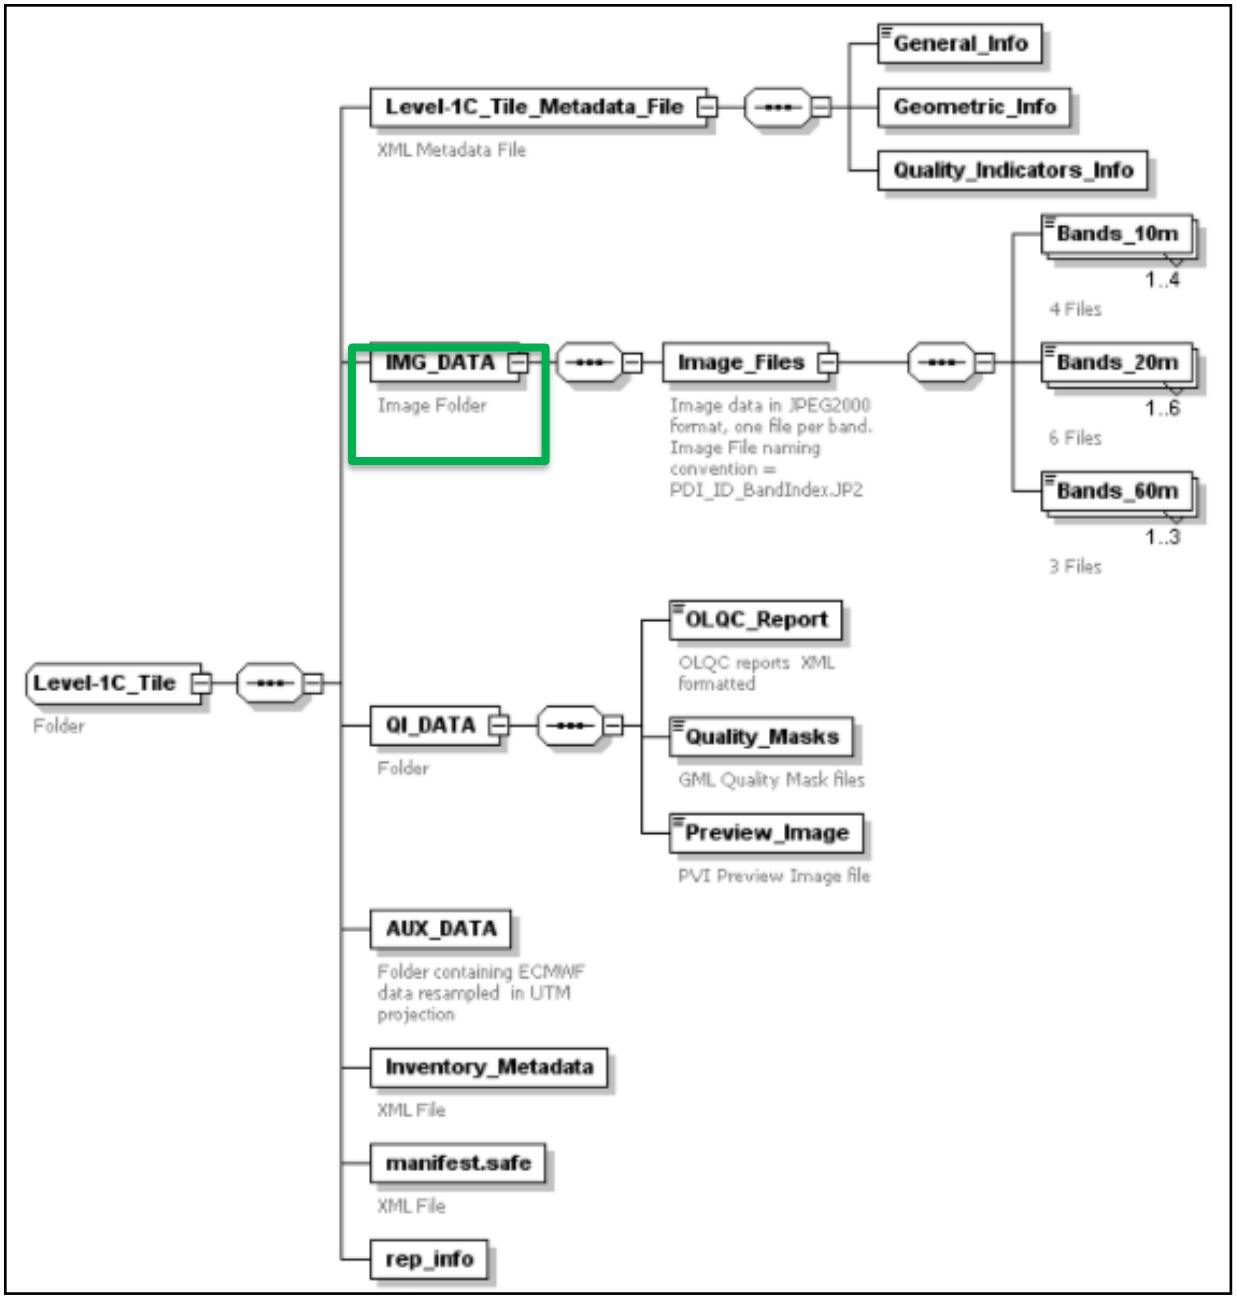

Figura 3: Distribución de carpetas de producto 1C.

Fuente: Sentinel-2-Product-Specifications-Document

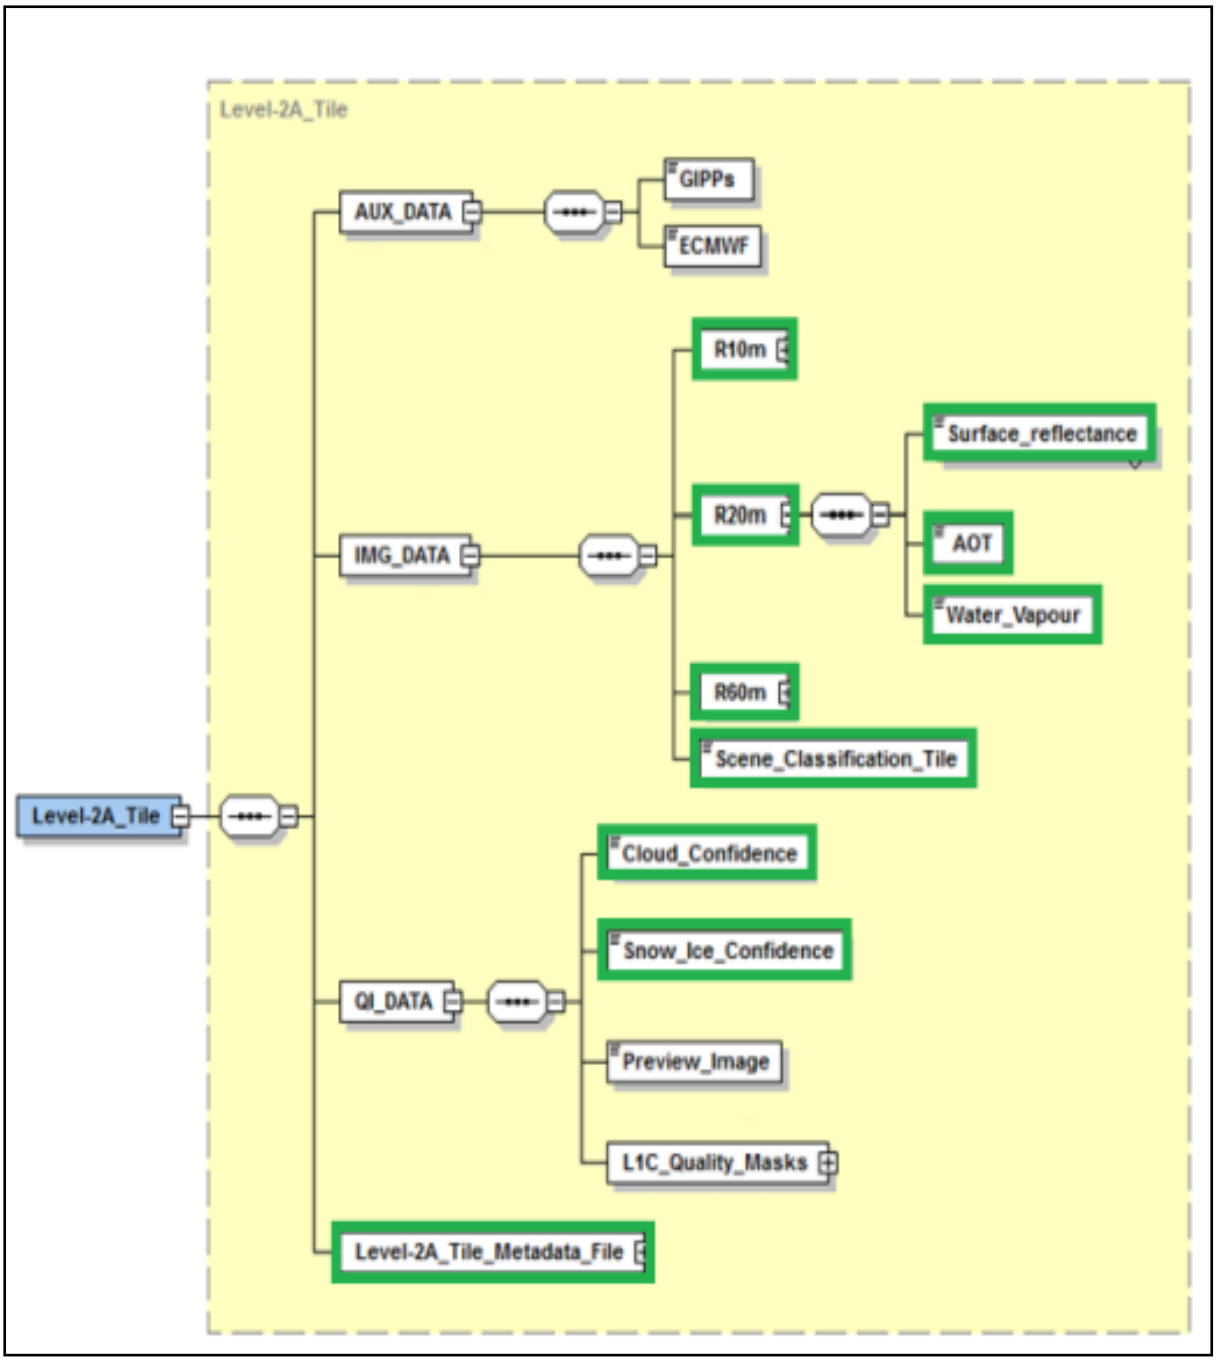

Figura 4: Distribución de carpetas de producto 2A.

Fuente: Sentinel-2-Product-Specifications-Document

3.5.2. Landsat-8

Los productos estándar L8, suministrados por el USGS-EROS CENTER (United States Geological Survey -Earth Resources Observation and Science) consisten en una serie cuantificada, calibrada y escalada de niveles digitales ND, los cuales representan los datos de una imagen multiespectral adquirida por ambos sensores: OLI (Operational Land Imagen) y el TIRS (Thermal Infrared Sensor) (Ariza A., 2013).

Las nuevas imágenes de L8 se pueden adquirir cada 16 días para cualquier ubicación. El satélite se lanzó en febrero de 2013. Contiene dos nuevos instrumentos de barrido de resolución radiométrica de 12 bits en formato GeoTIFF.

3.5.2.1 Corrección Atmosférica.

Los datos de las bandas del sensor TIRS y OLI pueden ser reescalados a los valores de reflectancia y/o radiancia a TOA, usando para ello los coeficientes radiométricos provistos en el archivo de metadato MTL.txt (Ariza A., 2013).

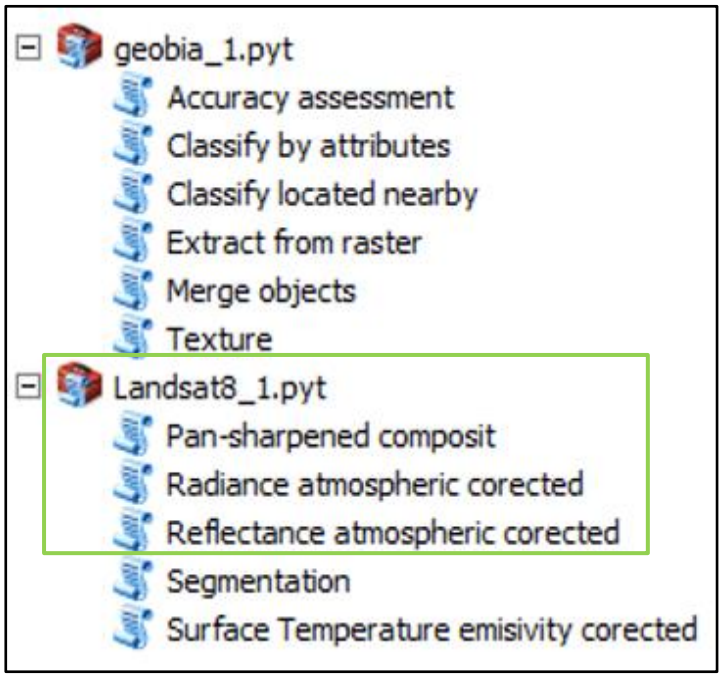

Figura 5: Estructura de Geobia - Toolbox.
(Fuente: Integration of Geobia with GIS for Semi-Automatic land cover mapping from Landsat 8 imagery)

Para agilizar los cálculos se utilizó una nueva herramienta para este proceso.GEOBIA (Geographic Object-Based Image Analysises) en términos simples, es un análisis basado en objetos de imágenes[6] de sensores remotos de la Tierra. Más específicamente, el análisis de imágenes basadas en objetos geográficos (GEOBIA) es una subdisciplina de las Ciencias de la Información Geográfica (Ciencia de GIS) dedicada a desarrollar métodos automatizados para particionar imágenes de detección remota en objetos de imagen significativos, y evaluando sus características a través de escalas espaciales, espectrales y temporales, a fin de generar nueva información geográfica en formato listo para utilizar en un GIS. (G. J., G. Castilla, 2008).

Recientemente fue creada una caja de herramientas Python diseñada exclusivamente para ArcGis aplicada en imágenes L8. Una de las secciones está destinada a la corrección atmosférica de datos sobre un área de interés (en adelante AOI) seleccionada. Todos los canales espectrales son remuestreados (Pan-sharpened) y corregidos atmosféricamente calculando la reflectancia (Jacek Urbanski, 2014), entre otros.

Pan-Sharpened es el proceso de fusionar una resolución espacial más alta pancromática (PAN) con imágenes multiespectrales (en adelante MS) de menor resolución espacial para crear imágenes de MS de resolución espacial más altas. (Khan Rubayet Rahaman; Quazi K. Hassan; M. Razu Ahmed, 2017).

[6] Análisis de imágenes basada en Objetos (OBIA): Estos objetos de la imagen son los grupos de píxeles que son similares entre sí sobre la base de una medida de las propiedades espectrales, es decir; color, tamaño, forma y textura, así como el contexto de un barrio que rodean los píxeles.

3.5.3 Clasificación Supervisada.

La clasificación digital consiste, en convertir la imagen satelital (imagen multibanda) en otra imagen del mismo tamaño, en la que cada píxel no contiene la cantidad de energía reflejada por los objetos o ND, sino una etiqueta que identifica el tipo de formación vegetal asignado a ese píxel (Chuvieco, 2008), asignándole un valor de clase a cada píxel de la imagen a partir de la respuesta espectral en cada una de las bandas. (Duzgun & Demirel, 2011).

Las clases que se distinguen en una clasificación de imágenes necesitan tener diferentes características espectrales. El principio fundamental es que a un píxel se le asigne una clase en base a su vector de características, comparándolo con grupos predefinidos en el espacio de características. Si lo hace para todos los píxeles de la imagen se traduce en una imagen clasificada. (Jensen, 2005)

El enfoque supervisado para el etiquetado de los píxeles requiere que el usuario seleccione los datos de entrenamiento representativos para cada número predefinido de clases. La clasificación es altamente dependiente de lo bien que el usuario sea capaz de modelar la distribución de clases. La experiencia del usuario puede ser muy útil en la identificación y localización de las áreas de formación. Lo ideal es que las áreas de entrenamiento deben ser los sitios donde se encuentran ejemplos homogéneos de los tipos de cobertura conocidos (Townshend, 1981).

4 METODOLOGÍA Y MATERIALES

4.1 ESQUEMATIZACIÓN DE METODOLOGÍA DE ESTUDIO.

- Selección de área de estudio.
- Adquisición de imágenes satelitales S2 1C y L8 Level 1, correspondientes a las fechas 11 de enero del 2017 y 2018 respectivamente.
- Pre procesamiento de imágenes mediante software SANP y ArcGis, para la realización de corrección atmosférica.
- Salida de campo.
- Post procesamiento utilizando el software Qgis. Recorte y creación de imágenes multibanda, aplicación de Índice de Vegetación de Diferencia Normalizada y Clasificación Supervisada.
- Estudio estadístico para estimar la calidad de información temática mediante matriz de confusión.
- Resultados y validación de resultados.

4.2 SELECCIÓN DE ÁREA DE ESTUDIO.

Se tomó el área de estudio sugerida por la Dirección General de Forestación, en la que se encuentra una buena porción de bosque nativo, la cual presenta un relevamiento previo de especies invasoras. La misma tiene como coordenadas en WGS84 21S UTM: extremo suroeste (546836,3;6190253,5), extremo noreste (576685,4;6235540,6).

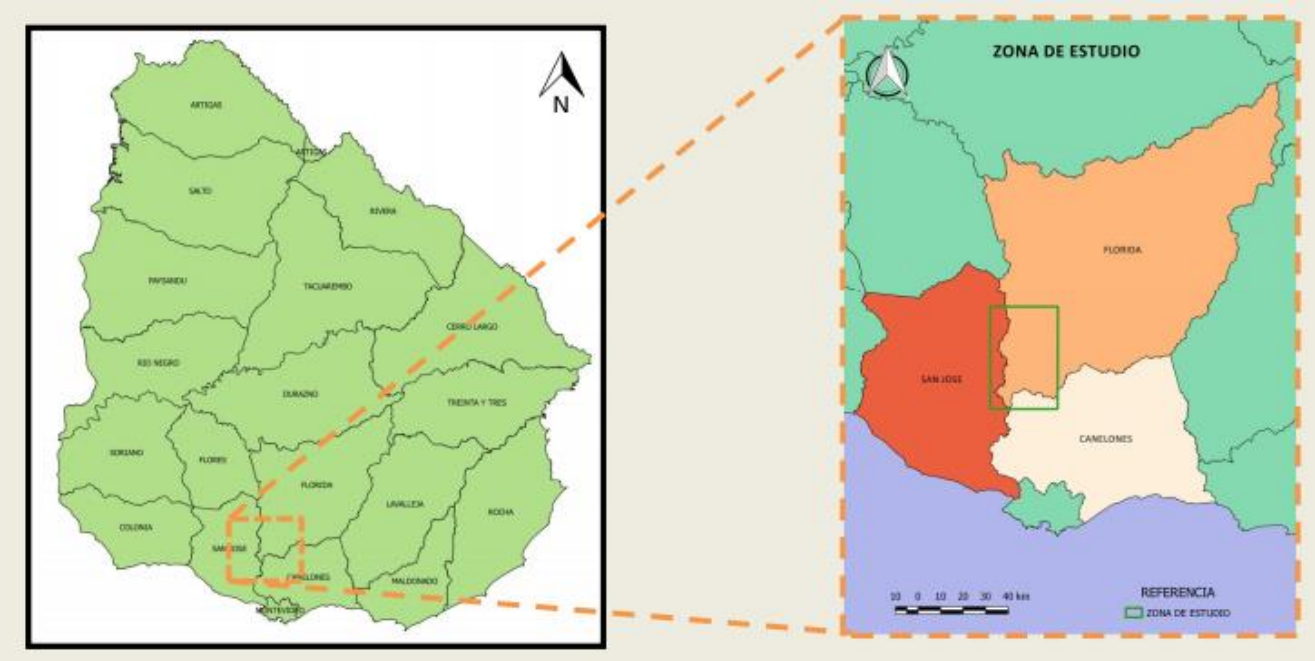

Figura 6: Zona de estudio. Fuente: Elaboración propia.

4.3 ADQUISICIÓN DE IMÁGENES.

Las imágenes fueron seleccionadas según los siguientes criterios:

- contener el área de estudio.
- ausencia de nubosidad.
- mismas fechas de captura de escena para ambos satélites.

Las fechas seleccionadas para el sensor S2 fueron 11 de enero de 2017 y 11 de enero de 2018, mientras que para el sensor L8, fue 11 de enero de 2017.

Estas imágenes fueron las únicas que cumplieron con los requisitos de selección.

4.4 GENERACIÓN DE IMÁGENES MULTIBANDA (corrección atmosférica, recorte y apilado de bandas)

Se corrigieron las imágenes de tal forma que sus píxeles arrojen valores de reflectancia. Por un lado, se comenzó trabajando con las imágenes S2. Para ello dentro del software SANP se dirige a la barra de *Herramientas/Optical/Thematic Land Processing/Sen2Cor,* dentro de las pestañas que se despliegan se debe colocar el parámetro solicitado *Metadato* del producto 1C y elegir la resolución espacial que desea corregir. Para este caso solo se corrigieron las de 10 y 20 metros ya que la de 60 contiene información que escapa a los fines de esta investigación. De esta manera se consigue un producto 2A del total de la imagen. Posteriormente se recortan con la herramienta de Qgis *Clipper* todas las bandas b2, b3, b4, b5, b6, b7, b8 y 8a utilizadas para el estudio.

En el caso de la imagen L8, se utilizó la caja de herramienta GEOBIA, se comienza cargando la caja en el ToolBox de ArcGis, luego se ejecuta el script python correspondiente al pan-sharpened. Para esta función, es necesario crear de antemano un rectángulo en formato shapefile que corresponde al AOI, utilizándose la zona de estudio como la misma. De esta manera se genera un conjunto de datos que se divide en cada banda con su respectivo tamaño igual a la zona de estudio, listos para ser corregidos atmosféricamente con las restantes herramientas. Cabe destacar que en los tres pasos se deben ingresar los metadatos de los productos creados de ante mano.

Mediante el complemento SCP (Clasificación Semi Automática) de Qgis se realiza el apilado de bandas. Las imágenes S2 se apilan según su resolución espacial, por un lado, las bandas de 10 m correspondientes al RGB (b3, b2, b1) más otra con NIR (b4, b3, b2) y las de 20 m solamente contienen las bandas b3 y b4 sumando alguna del Red-Edge. Mientras que las L8 solamente se apilan en color natural (b3, b2, b1) y falso color (b5, b4, b3).

Figura 7: Imagen S2 - 2017 de 10 metros. Color natural.

Figura 8: Imagen S2 - 2017 de 10 metros. Falso color.

Figura 9: Imagen S2 - 2018 de 10 metros. Color natural.

Figura 10: Imagen S2 - 2018 de 10 metros. Falso color.

Figura 11: Imagen L8 - 2017 de 30 metros. Color natural.

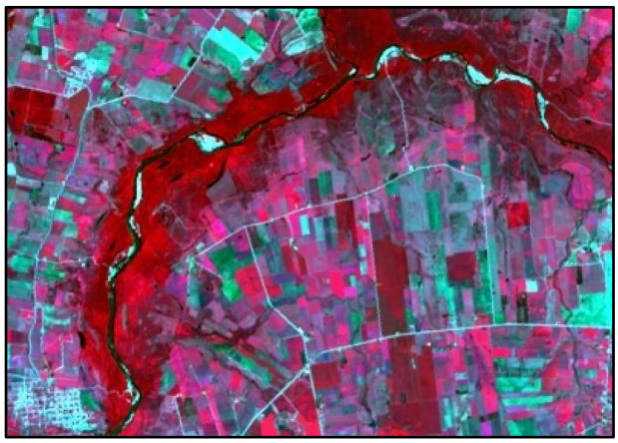

Figura 12: Imagen L8 - 2017 de 30 metros. Falso color.

4.5 ÍNDICE DE VEGETACIÓN DE DIFERENCIA NORMALIZADA (NDVI)

Chuvieco (1996: 86) menciona que cuando la vegetación sufre algún tipo de estrés (plagas, sequía, etc.), su reflectancia será inferior en el infrarrojo cercano y rojo, con lo que el contraste entre ambas bandas será mucho menor en relación con una vegetación sana de gran vigor. En síntesis, puede señalarse que, a mayor contraste entre las reflectancias de las bandas del infrarrojo y rojo, mayor vigor vegetal presentará una cobertura observada; por su parte, los bajos valores de esta relación indican una vegetación enferma o senescente, hasta llegar a coberturas sin vegetación como el suelo desnudo que reporta índices cercanos al cero (Soria et al., 1998: 39). Este índice toma valores entre –1 y 1 y es, sin lugar a duda, el más utilizado en aplicaciones agronómicas (Granados-Ramírez, 2004: 1620). Puede establecerse como umbral crítico para coberturas vegetales un valor de NDVI de 0.1, y para la vegetación densa, mayor a 0,5.

La ecuación utilizada para el cálculo del NDVI es la siguiente: NDVI = IRC – R / IRC + R, donde:

NDVI = índice, IRC = banda del infrarrojo cercano y R = banda del rojo.

Por cada imagen S2 se realizaron cuatro NDVI, uno con resolución espacial de 10 metros, utilizando la b8 correspondiente al IRC y la b4 correspondiente al rojo y los tres restantes con resolución espacial de 20 metros, utilizando las bandas espectrales Red-Edge (b5, b6 y b7) y b8a correspondiente al infrarrojo cercano. Las combinaciones de bandas utilizadas para los NDVI de 20 metros de resolución espacial fueron: b8a-b5; b7-b5; b6-b5, donde la banda espectral 5 ocupa siempre el lugar del rojo, variando la banda espectral que ocupa el lugar del infrarrojo cercano.

Con la imagen L8 solamente se realizó el NDVI convencional b4 y b5, ya que no cuenta con bandas espectrales Red-Edge y posee solamente una resolución espacial.

De esta manera, los índices realizados fueron los siguientes, para las imágenes S2:

- NDVI 84= banda 8 – banda 4 / banda 8+ banda 4
- NDVI 8a5= banda 8a – banda 5 / banda 8a + 5
- NDVI 75= banda 7 – banda 5 / banda 7 + banda 5
- NDVI 65 = banda 6 – banda 5 / banda 6 + banda 5

Para las imágenes Landsat-8 el NDVI aplicado fue el siguiente:

- NDVI 54 = banda 5 – banda 4 / banda 5 + banda 4

4.6 SALIDA DE CAMPO

El reconocimiento de la zona bajo análisis fue realizado el día 12 de diciembre de 2017, donde se colectaron 8 muestras (polígonos) en zonas ya definidas, con el fin de obtener tres patrones de bosque nativo:

- Ausencia de invasoras (AI), aquellas zonas donde la presencia de especies invasoras es nula o despreciable.
- Parcialmente afectados por invasoras (PAI), zonas de bosque nativo con invasión de especies invasoras considerable.

- Muy afectados por invasoras (MAI), zonas mayormente abarcadas por especies invasoras.

La siguiente tabla muestra la cantidad y coordenadas de las muestras colectadas.

Tabla 3: Muestras obtenidas en campo con GPS Garmin.

Muestras	Ausencia de invasoras	Parcialmente afectadas por invasoras	Muy afectadas por invasoras	Coordenadas del Centroide de la muestra (WGS84-UTM-21S)	
				x	y
1	O			557109,3	6194753,1
2			O	566858,2	6196372,8
3			O	566805,7	6196659,0
4		O		563716,8	6207771,6
5		O		563552,2	6207802,8
6	O			561271,6	6205000,3
7	O			560581,1	6198724,8
8	O			560452,7	6198562,8

Fuente: Elaboración propia. Ver mapa de distribución de puntos de muestras en anexo.

4.7 VALIDACIÓN NDVI

La validación de los diferentes índices se realizó utilizando las muestras obtenidas en campo.

Para cada índice se estudiaron los valores de NDVI de los píxeles pertenecientes a las muestras AI y MAI, comparándose unas con otras con los siguientes objetivos:

- Seleccionar cuál de los NDVI realizados denota una mayor diferenciación entre bosque nativo e invasoras. De cada muestra se extrajo el valor mínimo y máximo de NDVI, estableciéndose el bosque nativo más invasoras en el rango dado por el valor más alto de la muestra MAI y el más bajo de la muestra AI. A su vez se estableció el rango de bosque nativo a los valores que están entre el mínimo de la muestra AI y el mínimo de la muestra MAI y el rango de Invasoras a aquel que se encuentra entre el máximo de MAI y el máximo de AI. El rango de valores que esta entre el valor máximo de AI y el valor mínimo de MAI se lo considera de confusión, ya que son valores que pueden pertenecer a una clase como a la otra. Por último, se calculó el porcentaje de confusión el cual se denomina “% de confusión”. Siendo el índice con menor porcentaje de confusión el más apto para el estudio de la diferenciación del bosque nativo.
- Establecer rangos de valores de NDVI tanto para bosque nativo, como para invasoras. Una vez seleccionado el índice más apto para el estudio de diferenciación del bosque nativo, se procedió a extraer

los valores de píxeles de las muestras de campo restantes, con el fin de ajustar los rangos de clase.

4.8 CLASIFICACIÓN SUPERVISADA Y VALIDACIÓN.

Se generaron tres imágenes multibanda para enero 2017 y dos para enero 2018, según su resolución espacial.

- S2: 10 y 20 metros
- L8: 30 metros

Para la realización de las clasificaciones supervisadas, se utilizó el complemento de Qgis *deztsaka*[7] para cada apilado de bandas; como área de entrenamientos se tomaron las muestras de la Tabla 3, definiendo de esta manera tres clases dentro del bosque. Además, mediante interpretación visual de las imágenes se crearon tres clases más para el resto de la zona de estudio (agua, suelo cultivado y suelo desnudo).

Quedando definidas las siguientes clases:

- Ausencia de invasoras (1)
- Parcialmente afectado por invasoras (2)
- Muy afectado por invasoras (3)
- Suelo cultivado (4)
- Agua (5)
- Suelo desnudo (6)

Los resultados obtenidos de esta etapa se validaron mediante dos métodos:

- Matriz de confusión.
- Validación del modelo de clasificación utilizando muestras de validación aportadas por la Dirección General de Forestación. Se trata de muestras obtenidas del mismo modo que las muestras de entrenamiento, pero no utilizadas en la fase de clasificación.

Debido a que las muestras de la Tabla 4 están referenciadas como puntos, y son necesarios polígonos para efectivizar la validación, se procedió a la realización de un buffer de 50 metros tomando como centroide dichas muestras. Para la validación, se tomaron como correctas aquellas zonas donde por lo menos existe un píxel perteneciente a la clase previamente clasificada.

[7] Este plugin rápido y fácil de usar, ha sido desarrollado por Nicolas Karasiak; inicialmente basado para el modelo "Gaussian Mixture" desarrollado por Mathieu Fauvel; además se tiene la opción de trabajarlo desde la caja de procesado de Qgis.

Tabla 4. Caracterización de las muestras obtenidas en la zona.

Muestras	Ausencia de invasoras (AI)	Parcialmente afectadas por invasoras (PAI)	Muy afectadas por invasoras (MAI)	Coordenadas del Centroide de la muestra (WGS84-UTM-21S)	
				x	y
1		O		566562,4	6196469,5
2	O			566559,5	6196519,8
3			O	566724,8	6196505,6
4			O	566656,0	6196479,4
5			O	561671,1	6203833,1
6			O	573616,3	6195479,0
7			O	576255,7	6232421,4
8			O	574458,1	6228635,5
9	O			549919,8	6196591,2
10			O	551986,5	6200338,0
11			O	557404,2	6196544,9
12	O			557159,2	6194826,5
13		O		561140,4	6198415,2
14			O	566734,8	6196465,1
15	O			570641,4	6221067,8

Fuente: Elaboración propia, datos cedidos por DGF-MGAP. Ver mapa de distribución de puntos de muestras en anexo.

5 RESULTADOS Y DISCUSIÓN

5.1 ÍNDICE DE VEGETACIÓN DE DIFERENCIA NORMALIZADA (NDVI)

Al analizar las diferentes imágenes lo primero que se observa es la similitud de los valores en ambas muestras; comportamiento que se ve reflejado en la totalidad de los índices.

Esto genera que la diferenciación de rangos sea más compleja, ya que el umbral en donde se ubican ambas clases es prácticamente el mismo. Además, los resultados arrojan que la imágen L8 tienen un porcentaje de confusión notablemente más elevado que las imágenes S2. Este comportamiento se le puede atribuir a la baja resolución espacial y ausencia de la banda espectral Red-Edge.

Por otra parte, en la Tabla 5 se observa que los índices de enero de 2018 presentan menores porcentajes de confusión con respecto a los de enero de 2017. Esto puede deberse a las condiciones climáticas, ya que en el verano del 2018 se observa una menor precipitación y una mayor evapotranspiración que en el verano del 2017 (ver anexo “Datos climáticos INIA”). Estos fenómenos podrían estar afectando los estados naturales del ambiente, lo que genera que las especies autóctonas se debiliten y prosperen las exóticas invasoras. Los resultados sugieren que el bosque de ligustro estaría consumiendo mayor cantidad de agua, sobre todo en la época seca, debido a una actividad fenológica más prolongada respecto al bosque nativo (Nasca, et al, 2014).

Debido a que expone el porcentaje más bajo de confusión, el NDVI correspondiente al 8a5 de enero de 2018 es el que mejor presenta la discriminación de clases.

Tabla 5. Rangos de los distintos NDVI para cada periodo.

Fecha	**NDVI**	**Muestras**				**% de confusión**
		Ausencia de invasoras		**Muy afectadas por invasoras**		
		Valores por pixel				
		mínimo	**máximo**	**mínimo**	**máximo**	
Enero 2017	8a5	0,61799	0,73134	0,66263	0,75034	51,9
	75	0,56414	0,70445	0,64590	0,73408	34,5
	65	0,51771	0,63490	0,56421	0,65986	49,7
	84	0,81199	0,92993	0,88602	0,92025	40,6
	54	0,55603	0,68604	0,54744	0,66604	126,0
Enero 2018	8a5	0,66973	0,75369	0,72822	0,79924	19,7
	75	0,62001	0,73708	0,69136	0,78998	26,9
	65	0,54677	0,66018	0,61545	0,72060	25,7
	84	0,87122	0,94847	0,92340	0,97753	23,6
	54	-	-	-	-	-

Fuente: Elaboración propia.

Una vez seleccionado el NDVI 8a5, se ajustaron los rangos de clases, los cuales se disponen en la Tabla 6.

Este ajuste generó una reducción en el valor mínimo en AI por lo que a su vez se ve disminuido el porcentaje de confusión.

Tabla 6. Ajuste de rango de NDVI para las clases AI y MAI.

Fecha	NDVI	Muestras				% de confusión
		Ausencia de invasoras		Muy afectadas por invasoras		
		Valores por pixel				
		mínimo	máximo	mínimo	máximo	
Enero 2018	8a5	0,62879	0,75369	0,72822	0,79924	14,9

Fuente: Elaboración propia.

5.2 CLASIFICACIÓN SUPERVISADA.

Las clasificaciones para toda la serie de imágenes arrojaron una precisión de aproximadamente el 100 % según su matriz de confusión. Se considera como valor alto de precisión general a todo aquel valor mayor al 85 % (Anderson, et al 1976). Este alto nivel de precisión se justifica con las clases 4, 5 y 6, siendo la exactitud del usuario y del software prácticamente del 100%, debiéndose a que las muestras para esas categorías tuvieron una fácil fotoidentificación.

Para las bandas de 10 metros de la imagen S2 de enero 2017, las clases 1, 2 y 3 presentaron valores de exactitud del usuario superiores al 80%, mientras que la exactitud del software de las clases 1 y 2 superan el 82 %, y la clase 3, correspondiente a MAI presentó un 62,25 %. Este bajo valor se genera por la confusión con las clases 1 y 4.

Considerando los datos climáticos del verano del 2017 (ver anexo “Datos climáticos INIA”), ésta fue una época húmeda media-alta que superó la media histórica. Las precipitaciones y evapotranspiraciones son factores que influyen en la vegetación. A niveles normales de humedad, el ambiente genera que la vegetación se encuentre vigorosa, por lo tanto, el factor climático sumado a que esta clasificación se realizó utilizando las bandas espectrales en el visible e infrarrojo, limita la discriminación de las diferentes clases dentro del bosque nativo.

Sin embargo, la clasificación utilizando las bandas de 20 metros para la misma fecha, muestra que las clases 1 y 3 se presentan mejor discriminadas (95,93 % y 87,00%), mientras que la clase 2 bajó significativamente. La clase 2 a diferencia de las antes mencionadas, presenta errores más significativos. La buena diferenciación de especies en mezclas homogéneas se debe a que las bandas del Red-Edge captan las pequeñas variaciones en la pigmentación de las hojas mejorando los valores de clasificación. No obstante, la clase en donde existe una mezcla de especies el sensor no es capaz de separar la información captada debido a su baja resolución espacial, generalizando la misma y evidenciándose claramente que las clases se confundan su mayoría con el bosque nativo.

Con respecto a la imagen L8 del 2017, ésta presentó buenas precisiones para cada clase, aunque los altos

valores pueden deberse a los pocos píxeles que se evaluaron en la clasificación; lo que se intenta decir, es que los polígonos de las muestras homogéneas como heterogéneas interceptan pocos pixeles.

Tabla 7. Matriz de confusión para imagen Sentinel 2, enero 2017 bandas de 10 metros.

Clases	1	2	3	4	5	6	Error de comisión (%)	Exactitud del usuario (%)
1	884	18	79	0	0	0	9,89	90,11
2	27	116	0	0	0	0	18,88	81,12
3	18	0	249	0	0	0	6,74	93,26
4	55	7	72	9158	0	0	1,84	98,16
5	0	0	0	0	5395	0	0,00	100,00
6	0	0	0	4	1	5263	0,09	99,91
Error de omisión (%)	10,16	17,73	37,75	0,04	0,72	0,00		
Exactitud del software (%)	89,84	82,27	62,25	99,96	99,28	100,00		
Kappa	0,978							
Precisión General (%)	98,51							

Fuente: Elaboración propia.

Tabla 8. Matriz de confusión para imagen Sentinel 2, enero 2017 bandas de 20 metros.

Clases	1	2	3	4	5	6	Error de comisión (%)	Exactitud del usuario (%)
1	236	10	9	0	0	0	7,45	92,55
2	2	11	1	0	0	0	21,43	78,57
3	2	1	87	3	3	0	9,38	90,63
4	6	0	3	2292	2	0	0,48	99,52
5	0	0	0	0	1348	0	0,00	100,00
6	0	0	0	0	4	1314	0,30	99,70
Error de omisión (%)	4,07	50,00	13,00	0,13	0,66	0,00		
Exactitud del software (%)	95,93	50,00	87,00	99,87	99,34	100,00		
Kappa	0,987							
Precisión General (%)	99,14							

Fuente: Elaboración propia.

Tabla 9. Matriz de confusión para imagen Landsat 8, enero 2017 bandas de 30 metros.

Clases	1	2	3	4	5	6	Error de comisión (%)	Exactitud del usuario (%)
1	98	8	4	0	0	0	10,91	89,09
2	2	3	0	0	0	0	40,00	60,00
3	3	0	34	0	0	0	8,11	91,89
4	1	1	5	1027	1	0	0,77	99,23
5	0	0	0	0	600	0	0,00	100,00
6	0	0	0	0	4	591	0,67	99,33
Error de omisión (%)	5,77	75,00	20,93	0,00	0,83	0,00		
Exactitud del software (%)	94,23	25,00	79,07	100,00	99,17	100,00		
Kappa	0,982							
Precición General (%)	98,78							

Fuente: Elaboración propia.

Analizando la imagen de enero 2018 se nota una gran diferencia en lo que respecta a las condiciones agropecuaria y climáticas. Para esta fecha se observa una disminución en las precipitaciones y un aumento en la evapotranspiración, lo que genera una época de estrés hídrico ya que éstas se ubican por debajo de la media.

Los resultados no mostraron cambios significativos con respecto a las precisiones generales, aunque si evaluamos las exactitudes para cada clase en las imágenes 10 y 20 metros, esta última obtuvo un mayor aumento en los porcentajes de discriminación ubicándose la mayoría cercanos al 100 %, excepto la clase “PAI” que presentó casi un 90%.

Estos resultados son alentadores y se le atribuye a la presencia de la banda Red-Edge, la cual al trabajar con esa porción del espectro es capaz de identificar cambios del vigor de la vegetación en base principalmente al contenido de clorofila.

Las especies invasoras pueden mostrar una resistencia manteniendo sus niveles de clorofila normales, ya que algunas especies consumen una mayor cantidad de agua, sobre todo en la época de seca, debido a una actividad fenológica más prolongada respecto al bosque nativo. (Nasca, et al, 2014)

El alto porcentaje de fiabilidad, sumado a que las clases superan prácticamente el 90% permite deducir que la interpretación visual y los criterios utilizados para tomar las muestras de otras unidades fueron correctos, alejando así el error de clasificar pixeles en una categoría a la que no pertenecen.

Tabla 10. Matriz de confusión para imagen S2, enero 2018 bandas de 10 metros

Clases	1	2	3	4	5	6	Error de comisión (%)	Exactitud del usuario (%)
1	900	64	34	52	0	0	14,29	85,71
2	38	49	5	7	0	0	50,51	49,49
3	7	3	197	134	0	0	42,23	57,77
4	16	11	26	10475	21	54	1,21	98,79
5	0	0	0	0	5317	0	0,00	100,00
6	0	0	2	177	0	9663	1,82	98,18
Error de omisión (%)	6,35	61,42	25,38	3,41	0,39	0,56		
Exactitud del software (%)	93,65	38,58	74,62	96,59	99,61	99,44		
Kappa	0,965							
Precisión General (%)	97,61							

Fuente: Elaboración propia.

Tabla 11. Matriz de confusión para imagen Sentinel 2, enero 2018 bandas de 20 metros

Clases	1	2	3	4	5	6	Error de comisión (%)	Exactitud del usuario (%)
1	233	3	1	3	0	0	2,92	97,08
2	3	26	0	0	0	0	10,34	89,66
3	0	0	61	0	0	0	0,00	100,00
4	2	0	0	2685	5	1	0,30	99,70
5	0	0	0	0	1328	0	0,00	100,00
6	0	0	0	7	0	2451	0,28	99,72
Error de omisión (%)	2,10	10,34	1,61	0,37	0,38	0,04		
Exactitud del software (%)	97,90	89,66	98,39	99,63	99,62	99,96		
Kappa	0,995							
Precición General (%)	99,63							

Fuente: Elaboración propia.

Mediante una fotointerpretación de los resultados para el segundo método de validación Tabla 12 y Tabla 13, se desprende un 79 % y 69,2 % de coincidencia, estos son resultados alentadores para esta metodología de identificación. Es verdad que este método es totalmentemente cualitativo y acotado ya que se verifica con la existencia de al menos un pixel de la clase que se está evaluando. Además, estos resultados están sujetos a ciertas condiciones, como, por ejemplo: precisión y exactitud en la toma de las muestras, fecha de las muestras, porcentaje de ocupación de muestra, etc. La identificación de "SI" y "NO" corresponde a si existe al menos un píxel coincidente con la clase que se está validando.

Tabla 12. Coincidencia de la clasificación supervisada enero 2017 con muestras de la Dirección General de Forestación

Muestra	**Coincidencia – enero 2017**		
	Sentinel 2 - 10 m	**Sentinel 2 - 20 m**	**Landsat 8 - 30 m**
1	NO	NO	SI
2	SI	SI	SI
3	SI	SI	SI
4	SI	SI	SI
5	SI	SI	SI
6	SI	SI	SI
7	SI	SI	SI
8	NO	SI	NO
9	SI	SI	SI
10	SI	NO	NO
11	NO	NO	NO
12	SI	SI	SI
13	SI	NO	NO
% de coincidencia	76,9	69,2	69,2

Fuente: Elaboración propia.

Tabla 13. Coincidencia de la clasificación supervisada enero 2018 con muestras de la Dirección General de Forestación

Muestra	Coincidencia – enero 2018		
	Sentinel 2 - 10 m	Sentinel 2 - 20 m	Landsat 8 - 30 m
1	NO	NO	-
2	SI	SI	-
3	SI	SI	-
4	SI	SI	-
5	SI	SI	-
6	SI	SI	-
7	SI	SI	-
8	NO	NO	-
9	SI	SI	-
10	NO	NO	-
11	SI	NO	-
12	SI	SI	-
13	SI	SI	-
% de coincidencia	76,9	69,2	-

Fuente: Elaboración propia.

En la siguiente tabla se pueden observar los resultados obtenidos a partir de la vectorización del procesamiento de las distintas imágenes.

Tabla 14. Superficie de bosque, discriminada según clases

Año	Resolución Espacial (m)	Ausencia de Invasoras		Parcialmente Afectado por Invasoras		Muy Afectado por Invasoras		Superficie Total
		ha	%	ha	%	ha	%	ha
2017	10	1985,34	43,71	1981,54	43,63	575,21	12,66	4542,09
	20	2026,86	53,30	143,38	3,77	1632,77	42,93	3803,02
	30	2805,55	82,28	362,50	10,63	241,54	7,08	3409,59
2018	10	1636,91	46,76	852,02	24,34	1012,01	28,91	3500,94
	20	2913,52	68,40	457,90	10,75	887,96	20,85	4259,39

Fuente: Elaboración propia.

6 CONCLUSIONES

El desarrollo de una metodología para la identificación de especies invasoras dentro del bosque nativo, mediante el estudio de imágenes satelitales Sentinel 2, permitió conseguir valores de exactitud satisfactorios para las clases en cuestión.

En primera instancia los resultados que se verifican por parte de los distintos NDVI no son suficientes para discriminar con fiabilidad las distintas clases dentro del bosque nativo, debido a que estos clasifican a los pixeles por el valor que contienen sin tomar en cuenta la resolución espacial, máximos, mínimos, la proximidad a otros pixeles, textura, etc. Sin embargo, la combinación de una banda de Red-Edge con el infrarrojo cercano, puede llevar a una mejora en los resultados de la clasificación. No obstante, debe considerarse que una época seca colabora en la identificación, ya que los niveles de pigmentación de las distintas especies son captados susceptiblemente por la banda Red-Edge.

En este sentido el NDVI 8a5 supone una base fundamental para acercarse a la existencia de especies invasoras en el bosque nativo, no así se asegura que presente exactitudes elevadas de discriminación.

Las evaluaciones de las distintas clasificaciones supervisadas arrojan, que la realizada utilizando las bandas espectrales de 20 metros de la imagen Sentinel 2 del 2018 presentó mayor discriminación para las tres clases en cuestión, superando prácticamente el 90% de exactitud. Esto permitió visualizar regiones invadidas con mayor fiabilidad, pudiendo determinar un área total de bosque de 4259,39ha, siendo el 20,85% Muy Afectada por Invasoras, 10,75% Parcialmente Afectada por Invasoras y el restante 68,4% Ausencia de Invasoras, siendo éste un resultado para tener presente.

En tanto la misma clasificación realizada para la imagen del 2017 presentó un 42,93% Muy Afectada por Invasoras, 3,77% Parcialmente Afectada por Invasoras y 53,30% Ausencia de Invasoras, teniendo el bosque un área total de 3803,02ha. Estos datos son aún más alarmantes que los anteriores, pero hay que tener presente que por más que sus valores de exactitud fueron relativamente buenos, no se dieron en las mejores condiciones ambientales.

Cabe destacar, que estas áreas se obtuvieron de información vectorial a partir de las clasificaciones supervisadas. Se trabajó de esa manera por su fácil y rápido procesamiento, y distribución.

Con respecto a la salida de campo, se sugiere que la recolección de muestras sea en forma poligonal y no un punto, de esta forma a la hora de clasificar las imágenes se logran mejores y más precisas aéreas de interés, como así también debe considerarse el tamaño de la misma. De antemano, debe saberse la resolución espacial de las imágenes con las que se va a trabajar para así no provocar inconsistencias a la hora del proceso de identificación. Además, se sugiere que la categorización para la muestra de clasificación supervisada no exceda un máximo de tres categorías, de esta forma se reducen bruscamente las confusiones del software y mejora la discriminación de clases.

La nueva misión Sentinel 2 abre una puerta de infinitas posibilidades en lo que respecta a la detección de cobertura vegetal, por lo que concluimos que esta potente herramienta aporta significativamente resultados positivos. No obstante, es necesario un buen trabajo de campo complementario, de manera que la información generada tenga un mayor grado de confiabilidad.

7 BIBLIOGRAFÍA

- Agencia Europea espacial: *Sentinel online*

  Fecha de consulta: 17/042017

  Disponible en: https://sentinel.esa.int/web/sentinel/home

- Ariza, A. 2013. *Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission)*: [PDF]. Instituto Geográfico Agustín Codazzi. Versión 1.0. Colombia.

- Borrás, J. [et al.] 2017. *Clasificación de usos del suelo a partir de imágenes Sentinel-2:* Laboratorio de Procesado de Imágenes, Universidad de Valencia. C/ Catedrático José Beltrán, 2. 46980 Paterna, València - España.

  ISSN: 1133-0953.

- Cartaya, S. [et al.] 2014. *Comparación de técnicas para determinar cobertura vegetal y usos de la tierra en áreas de interés ecológico, Manabí, Ecuador*: [PDF]. Universidad Distrital Francisco José de Caldas, Facultad de Ingeniería - Facultad del Medio Ambiente y Recursos Naturales.

  doi: http://dx.doi.org/10.14483/udistrital.jour.udgeo.2014.9.a01

- Castro, D.; Peñaloza, F. 2015. *Metodología para la identificación de especies vegetales invasoras Ulex europaeus (retamo espinoso) y Genista monspessulana (retamo liso) en zonas piloto de Bogotá D.C usando imágenes multiespectrales de alta resolución:* [PDF]. Universidad Distrital Francisco José de Caldas Facultad de ingeniería, Ingeniería Catastral y Geodesia Bogotá, Colombia.

- Chuvieco, E. 1996. *Fundamentos de Teledetección Espacial. Tercera Edición Revisada.* Ediciones RIALP, S.A.: Madrid, España.

- Delegido, J. [et al.] 2016. *APLICACIONES DE SENTINEL-2 A ESTUDIOS DE VEGETACIÓN Y CALIDAD DE AGUAS CONTINENTALES:* [PDF]. Laboratorio de Procesado de Imágenes, Universidad de Valencia. XVII Simposio Internacional SELPER 2016, Valencia, España.

  ISBN: 978-987-3941-14-6

- ESA, 2016. *Sen2Cor Configuration and User Manua:* [PDF]

- ESA, 2016. *Sentinel-2 Products Specification Document*: [PDF]

- ESA, 2016. *Sentinel-2 User Handbook*: [PDF]

- Geo innova. *Analisis de las aplicaciones de SNAP (Sentinel application Plataform) para trabajar con imágenes* aéreas: [sitio web].

  Fecha de consulta: 13/08/2017

  Disponible en: https://geoinnova.org/blog-territorio/gis-aplicacion-snap-imagenes-aereas/

- Hay, G.; Castilla, G. 2017. *Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline:* Department of Geography, University of Calgary, 2500 University Dr. NW, Calgary.

- Jiménez Escudero, V. M. 2015. *DESARROLLO DE METODOLOGÍA DE TELEDETECCIÓN PARA LA DISTRIBUCIÓN ESPACIAL DE LA PLAGA MARABÚ (DICHROSTACHYS CINÉREA) EN TRINIDAD-VALLE DE LOS INGENIOS (PATRIMONIO CULTURAL DE LA HUMANIDADUNESCO)*: [PDF]. Universidad Internacional de Andalucía.

  ISBN: 978-84-7993-722-5, Cuba.

- Khan Rubayet Rahaman; Quazi K. Hassan; M. Razu Ahmed, 2017. Pan-Sharpening of Landsat-8 Images and Its Application in Calculating Vegetation Greenness and Canopy Water Contents. Department of Geomatics Engineering, Schulich School of Engineering, University of Calgary, Calgary, Canada.

  Disponible en: http://www.mdpi.com/2220-9964/6/6/168/htm

  doi:10.3390/ijgi6060168

- León, A.A. 2015. *Descripción, Descarga y Manipulación de Productos Sentienl-2:* [PDF].

- Nasca, L., [et al.]. 2014. *Efectos de la invasión del ligustro, Ligustrum lucidum, en la dinámica hídrica de las Yungas del noroeste Argentino:*

  doi: 10.4067/S0717-92002014000200007

- Nobel, J. P., [et al.] 2006. *LA CONTAMINACIÓN DEL BOSQUE NATIVO POR*

  ESPECIES ARBÓREAS Y ARBUSTIVAS EXÓTICAS: [PDF]. DGF-MGAP, Uruguay.

- Pérez Gutiérrez, C.; Muñoz Nieto, Á. L. 2006: *Teledetección: Nociones y Aplicaciones*. [PDF] Universidad de Salamanca.

- Ruiz, R. J; Granados Ramírez, R. 2005. *Relación entre los índices de vegetación obtenidos de los sensores AVHRR del satélite NOAA y TM del Landsat:* CIENCIA ergo-sum, Revista Científica Multidisciplinaria de Prospectiva en línea 2005.

  ISSN: 1405-0269

- Soria, R. J.; C. Ortiz; F. Islas; V. Volke 1998. *Sensores remotos, principios y aplicaciones en la evaluación de los recursos naturales. Experiencias en México:* [PDF]. Publicación especial 7. Sociedad Mexicana de la Ciencia del Suelo, Chapingo, México.

- Sosa, B.; Chiale, C., [et al.]. *Potencialidad de las imágenes satelitales de alta resolución en la detección de especies leñosas invasoras*: Laboratorio de Desarrollo Sustentable y Gestión Ambiental del Território Facultad de Ciencias UdelaR.

- Urbanski, J. 2016. *Geobia for Arcgis*. Integration of Geobia with GIS for Semi-Automatic land cover mapping from Landsat 8 imagery. Presented at 5th GEOBIA conference 21 – 24 May in Thessaloniki.

  Disponible en: http://cgis.oig.ug.edu.pl/CentrumGIS/GEOBIA%20in%20ArcGIS.pdf

- Zaraza, M.A. 2015. *Metodología de la Investigación, banda Red-Edge.*

  Fecha de consulta: 12/05/2018

  Disponible en: http://maikolzaraza.blogspot.com/2015/08/banda-del-red-edge.html

8 ANEXO

i. Datos climáticos INIA, verano 2017 y 2018.

ii. Distribución de muestras de campo.

iii. Representación visual de Índice de Vegetación de Diferencia Normalizada 84 enero 2017.

iv. Representación visual de Índice de Vegetación de Diferencia Normalizada 65 enero 2017.

v. Representación visual de Índice de Vegetación de Diferencia Normalizada 75 enero 2017.

vi. Representación visual de Índice de Vegetación de Diferencia Normalizada 8a5 enero 2017.

vii. Representación visual de Índice de Vegetación de Diferencia Normalizada 84 enero 2018.

viii. Representación visual de Índice de Vegetación de Diferencia Normalizada 65 enero 2018.

ix. Representación visual de Índice de Vegetación de Diferencia Normalizada 75 enero 2018.

x. Representación visual de Índice de Vegetación de Diferencia Normalizada 8a5 enero 2018.

xi. Presencia de especies invasoras en Bosque Nativo (Clasificación Supervisada Sentinel 2 enero 2017, 20 metros).

xii. Presencia de especies invasoras en Bosque Nativo (Clasificación Supervisada Sentinel 2 enero 2018, 20 metros).

Datos climáticos de enero 2017-2018 para la zona de Santa Lucía. (Las Brujas, INIA).

Tabla 1: Balance hídrico veranos 2017 y 2018

	Pp (mm)	***Etp (mm)***	***Balance***
2017	*126*	*134*	*-8*
2018	*69*	*160*	*-91*
Histórico (1972-2018)	*100*	*165*	*-65*

.

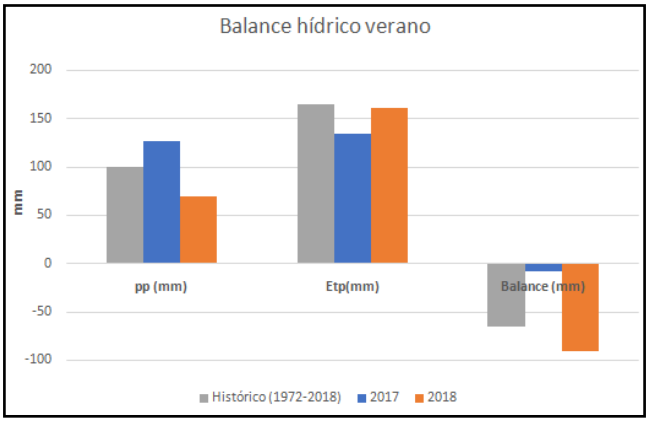

Figura 1: Balance hídrico veranos 2017 y 2018.

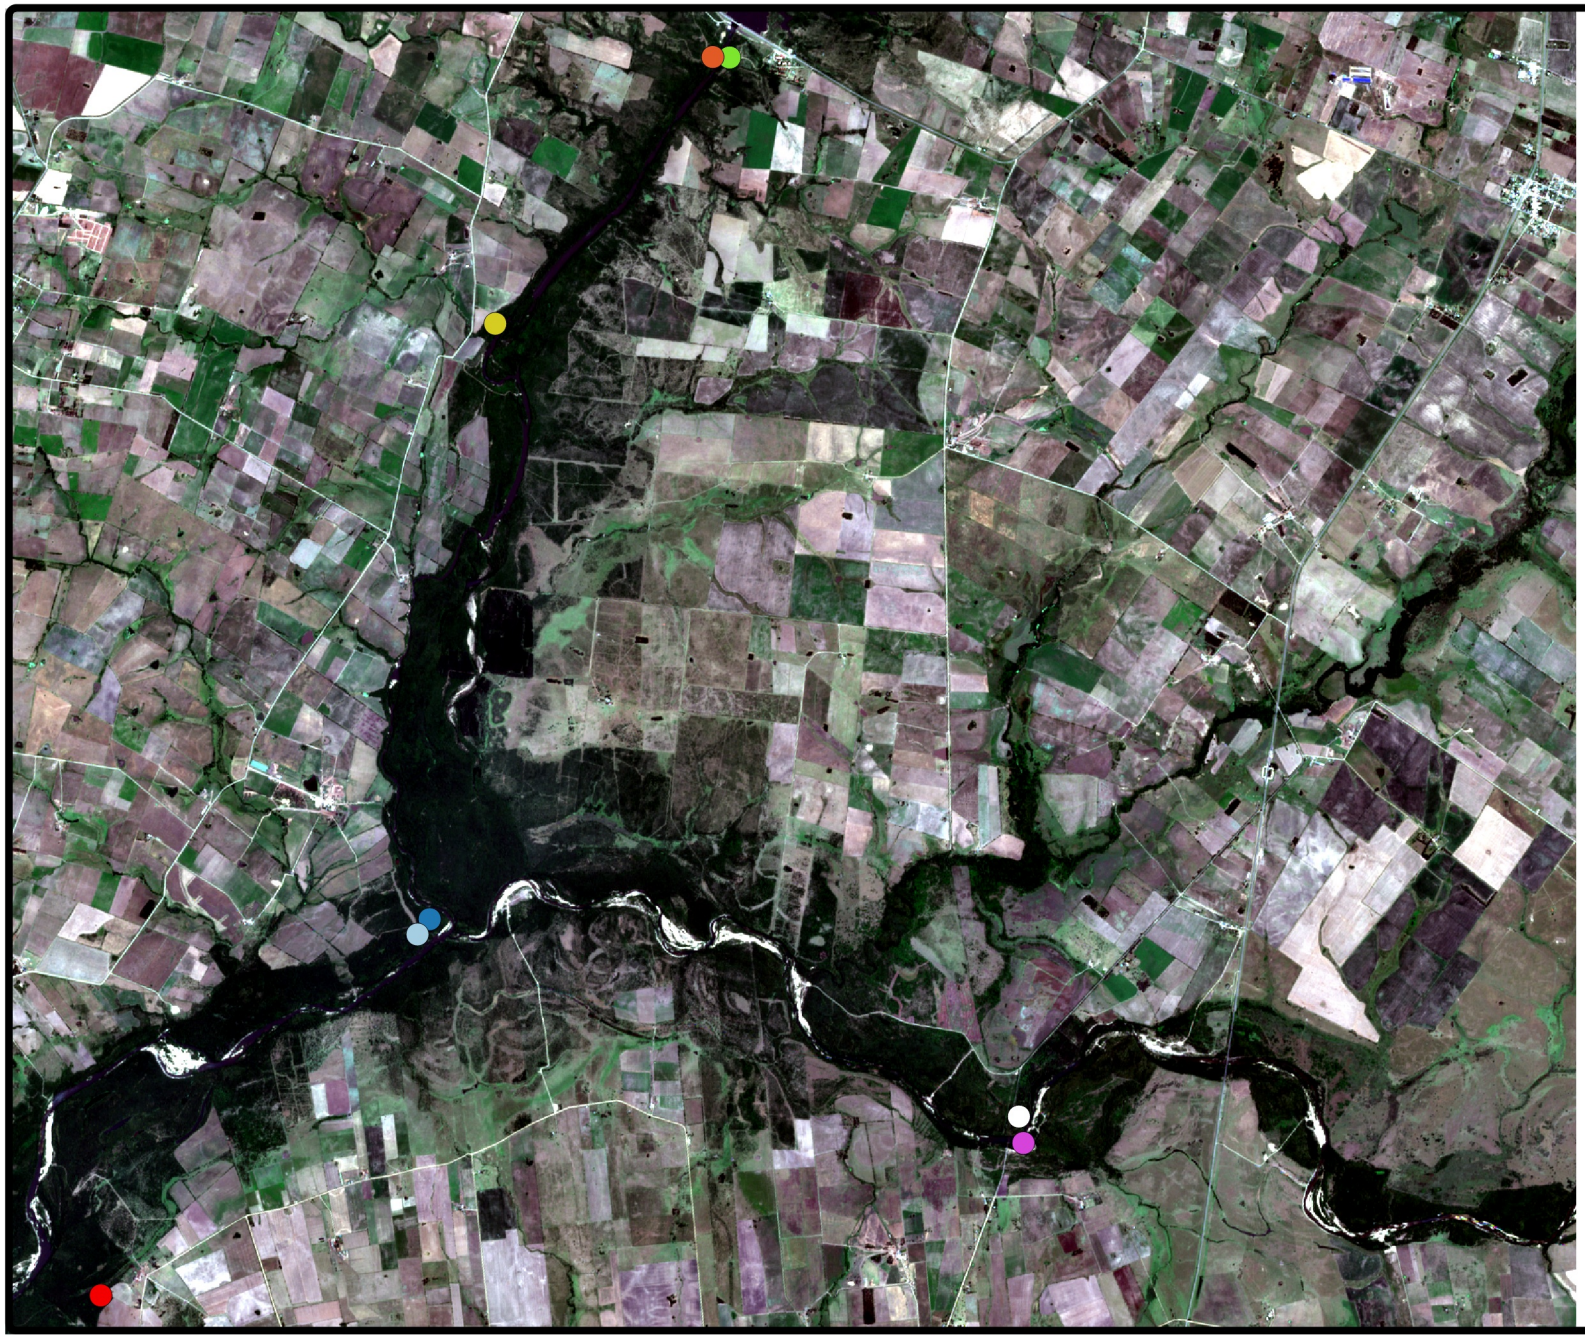

Distibución de muestras de campo

N
O E
S

Referencias

Muestras

- 1
- 2
- 3
- 4
- 5
- 6
- 7
- 8

Sistema de Referencia: WGS84 - UTM 21S

Muestra	Coord x	Coord y
1	557114.4	6194758.9
2	566838.1	6196364.8
3	566790.7	6196644
4	563741.2	6207807.7
6	561271.6	6205001.8
7	560580.4	6198724.5
8	560452	6198563.8

Escala: 1:80.000

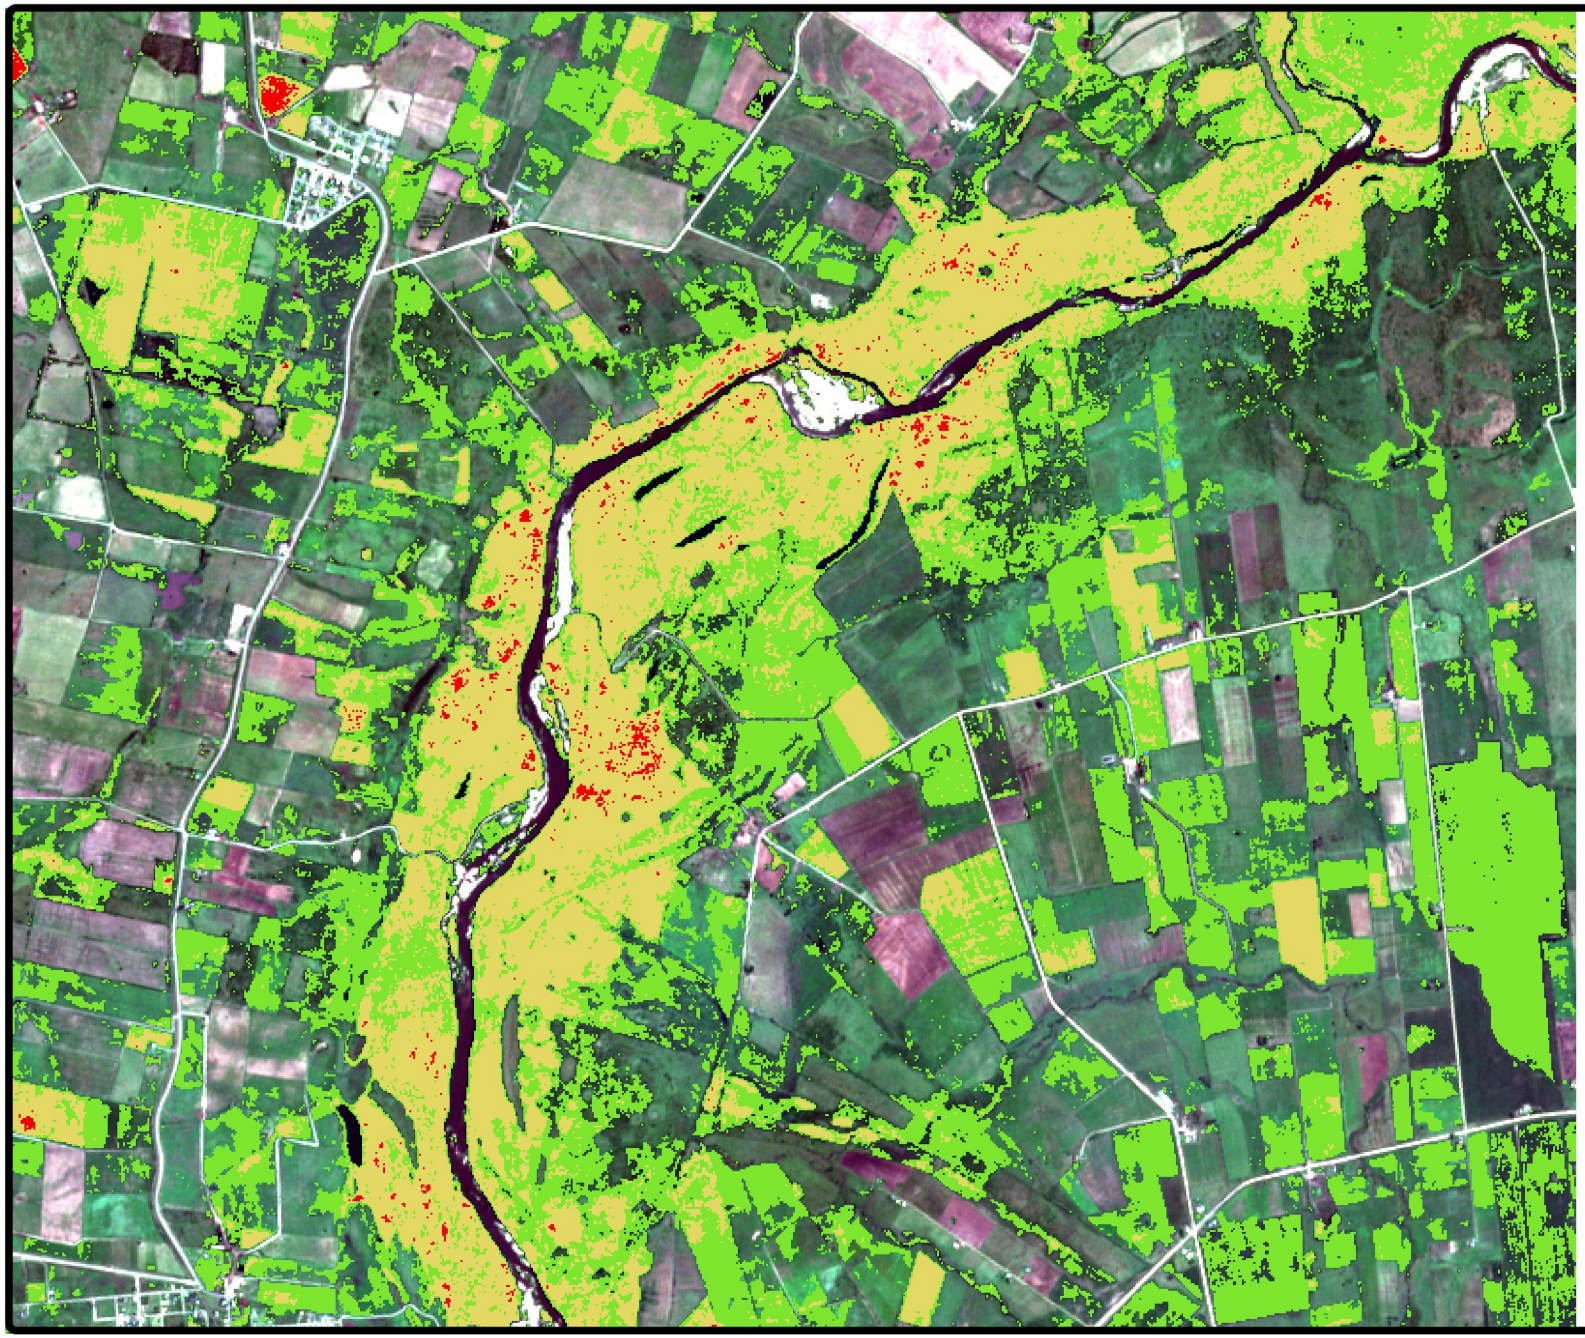

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 84)

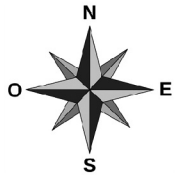

Referencias

NDVI 84 Enero 2017

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

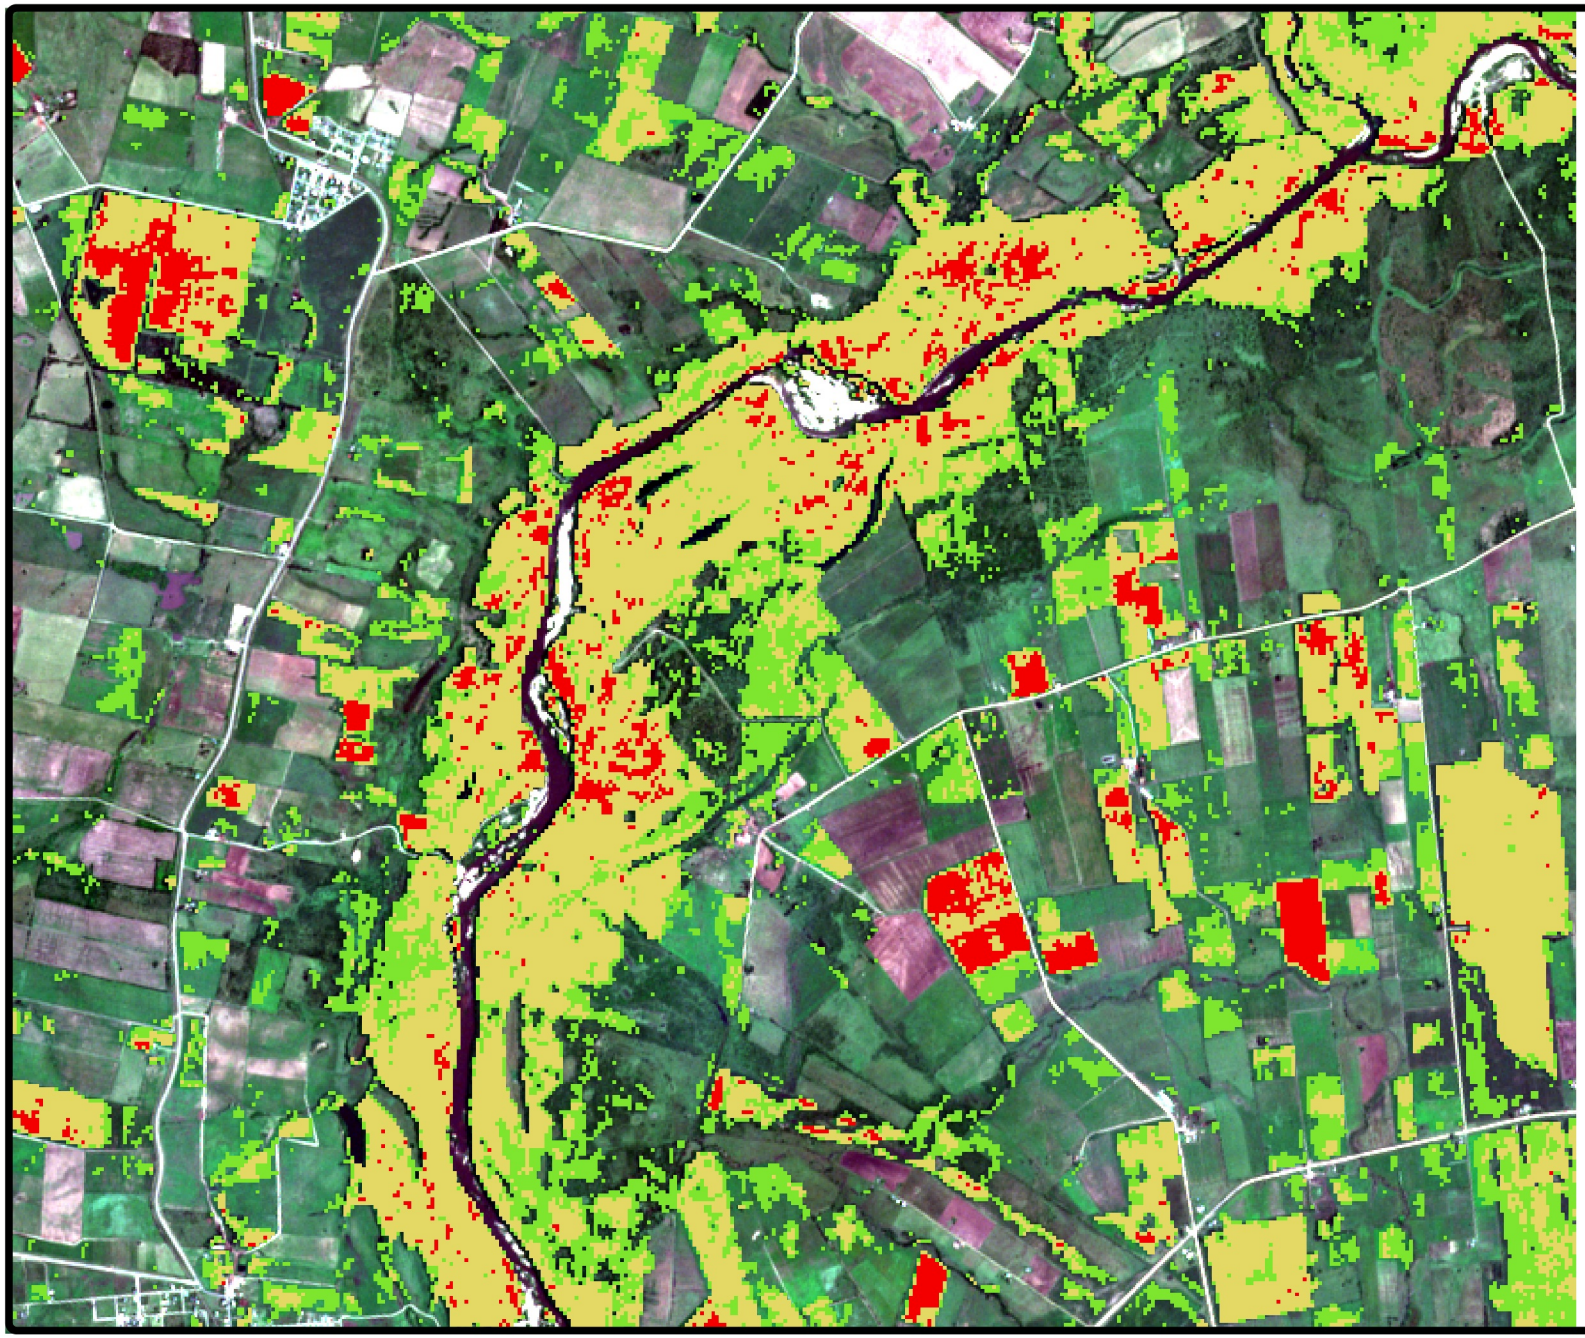

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 65)

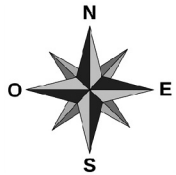

Referencias

NDVI 65 Enero 2017

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

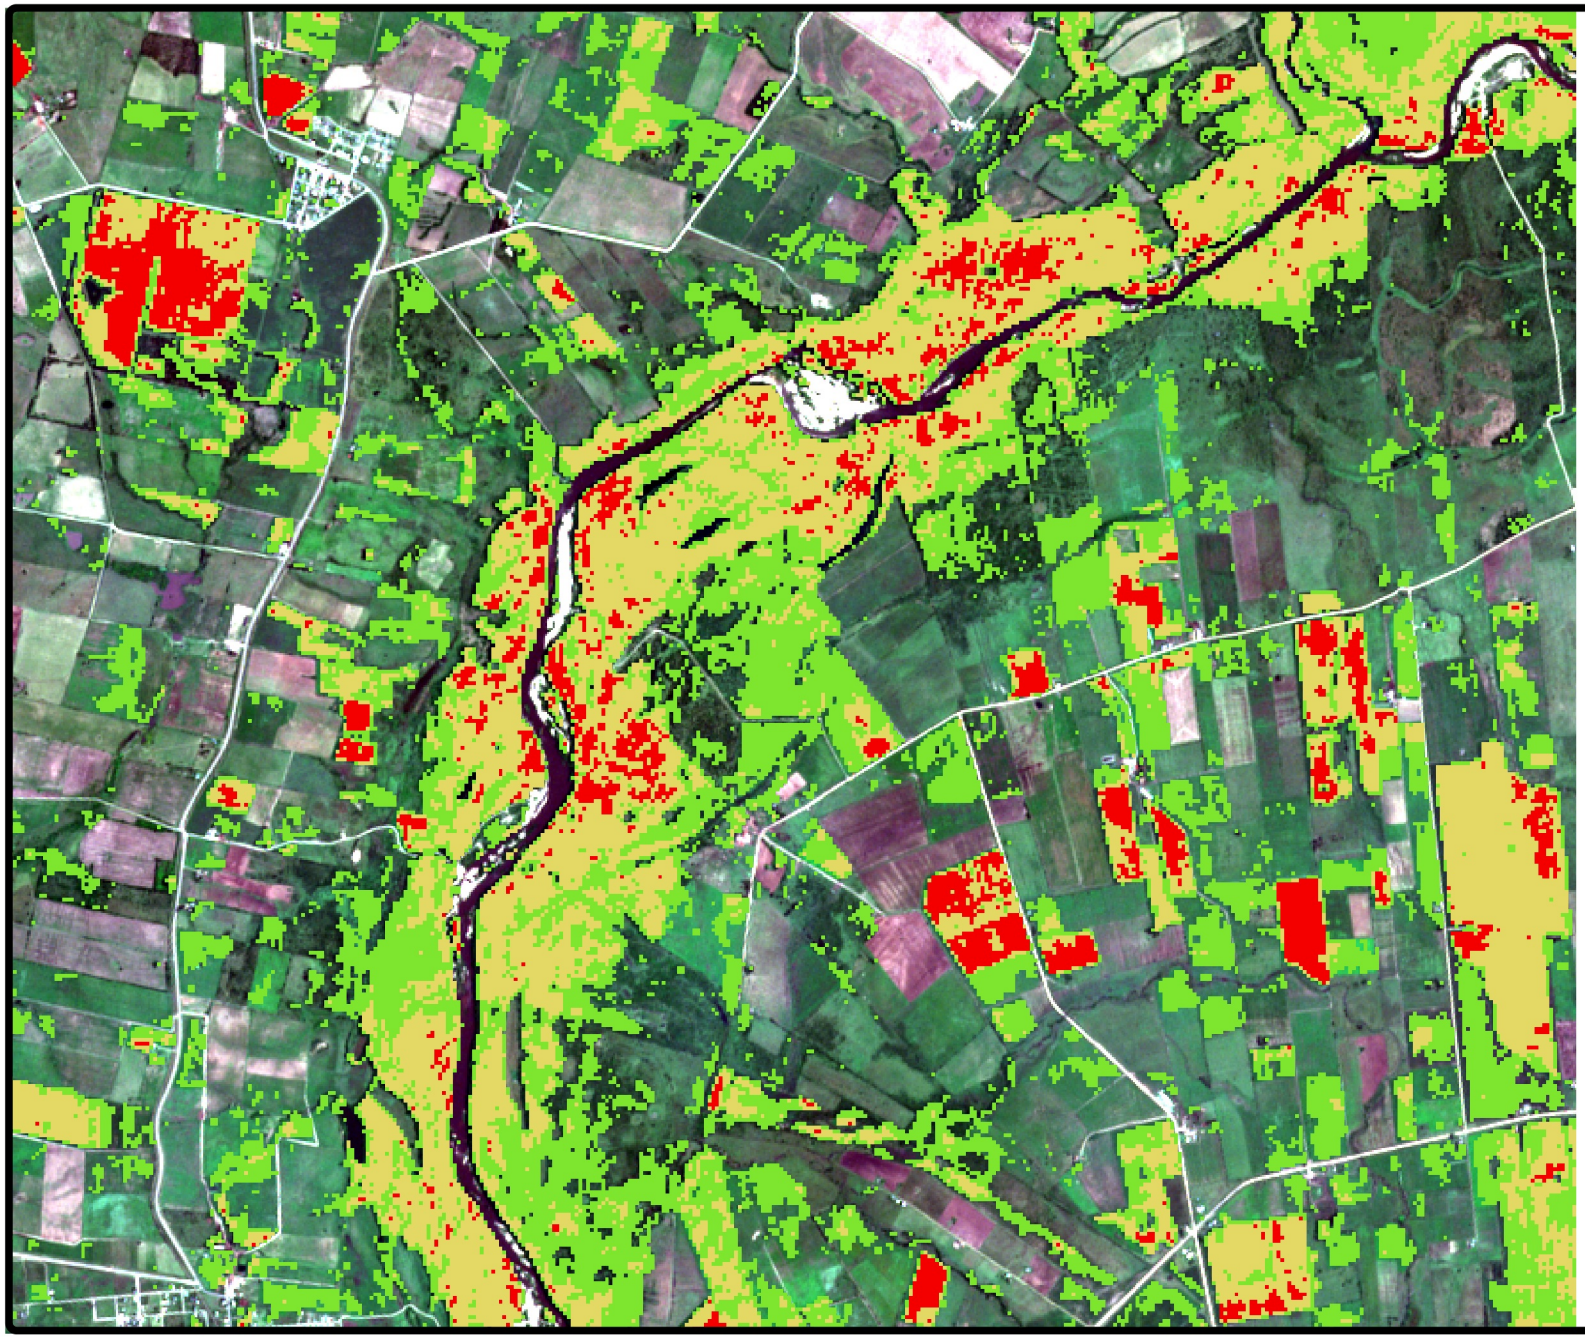

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 75)

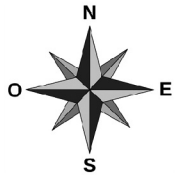

Referencias

NDVI 75 Enero 2017

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

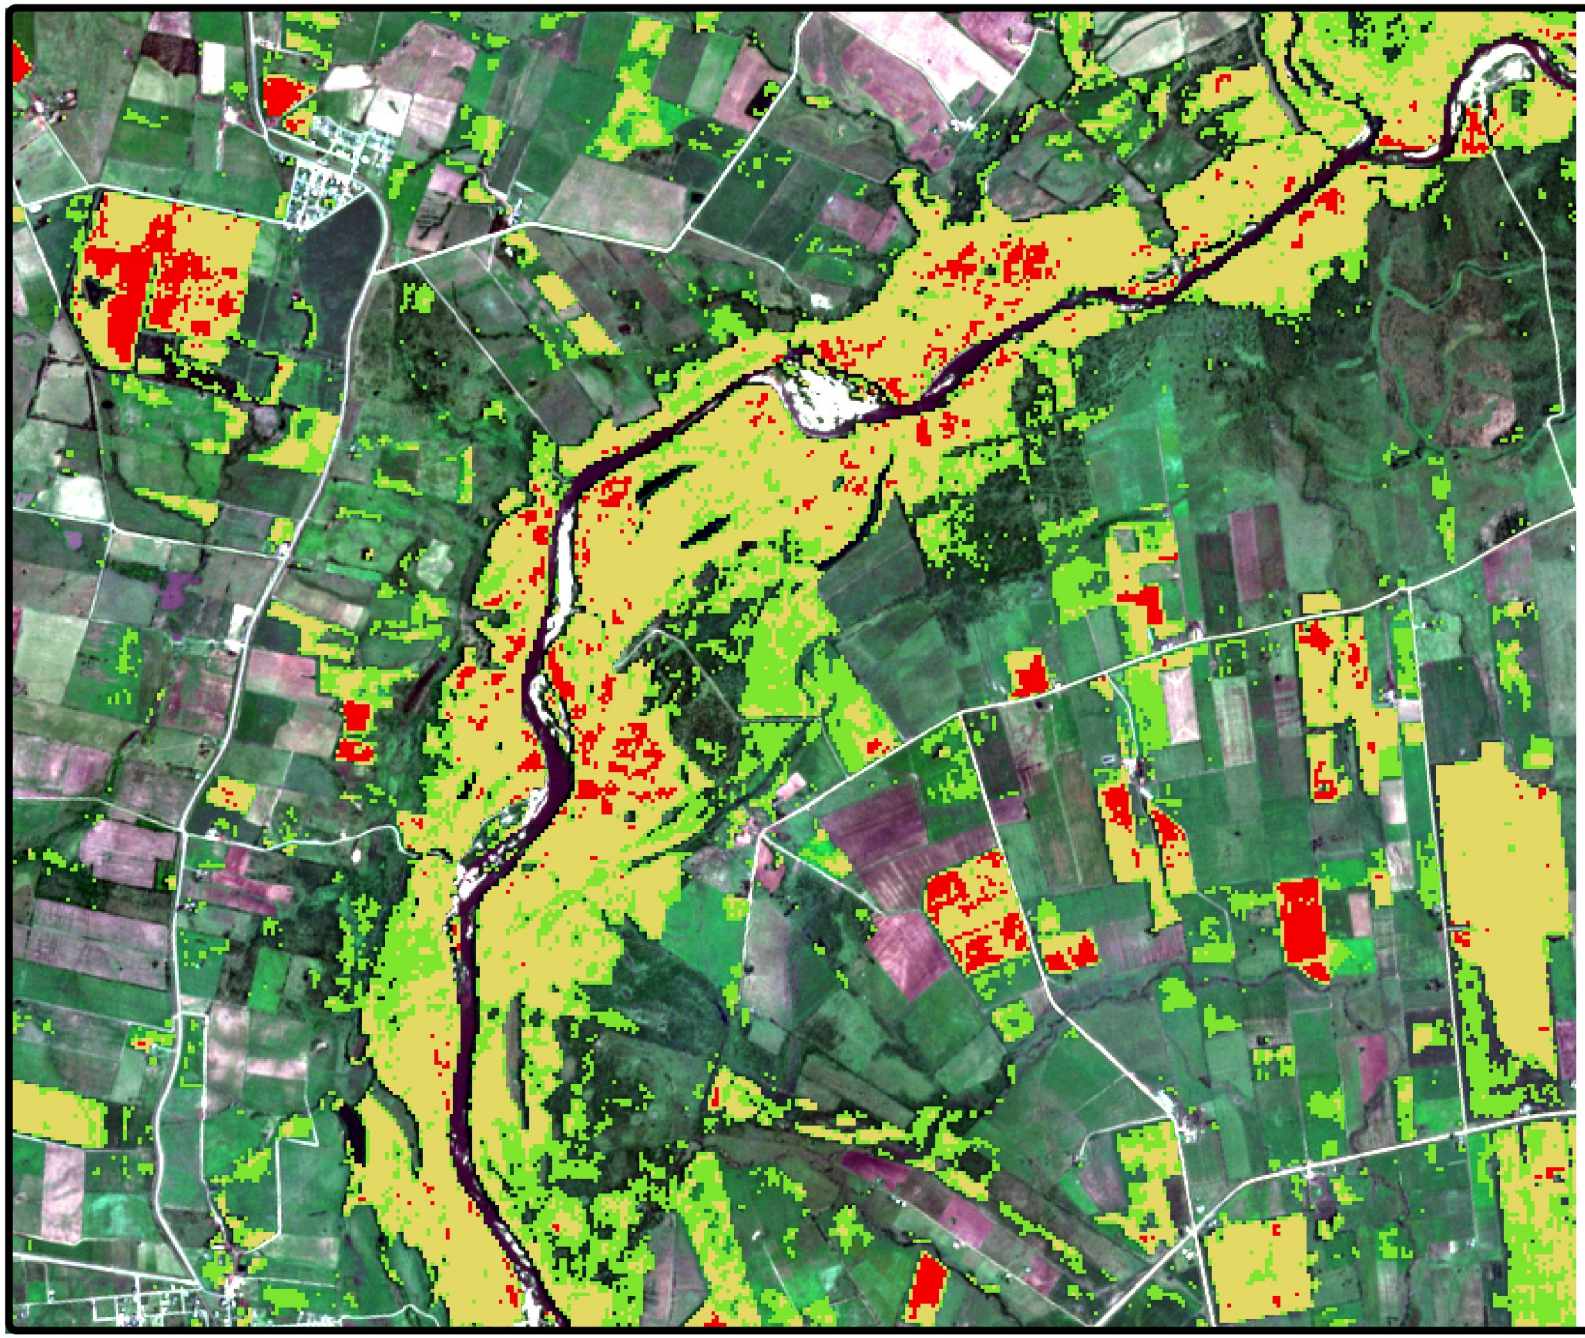

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 8a5)

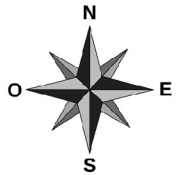

Referencias

NDVI 8a5 Enero 2017

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

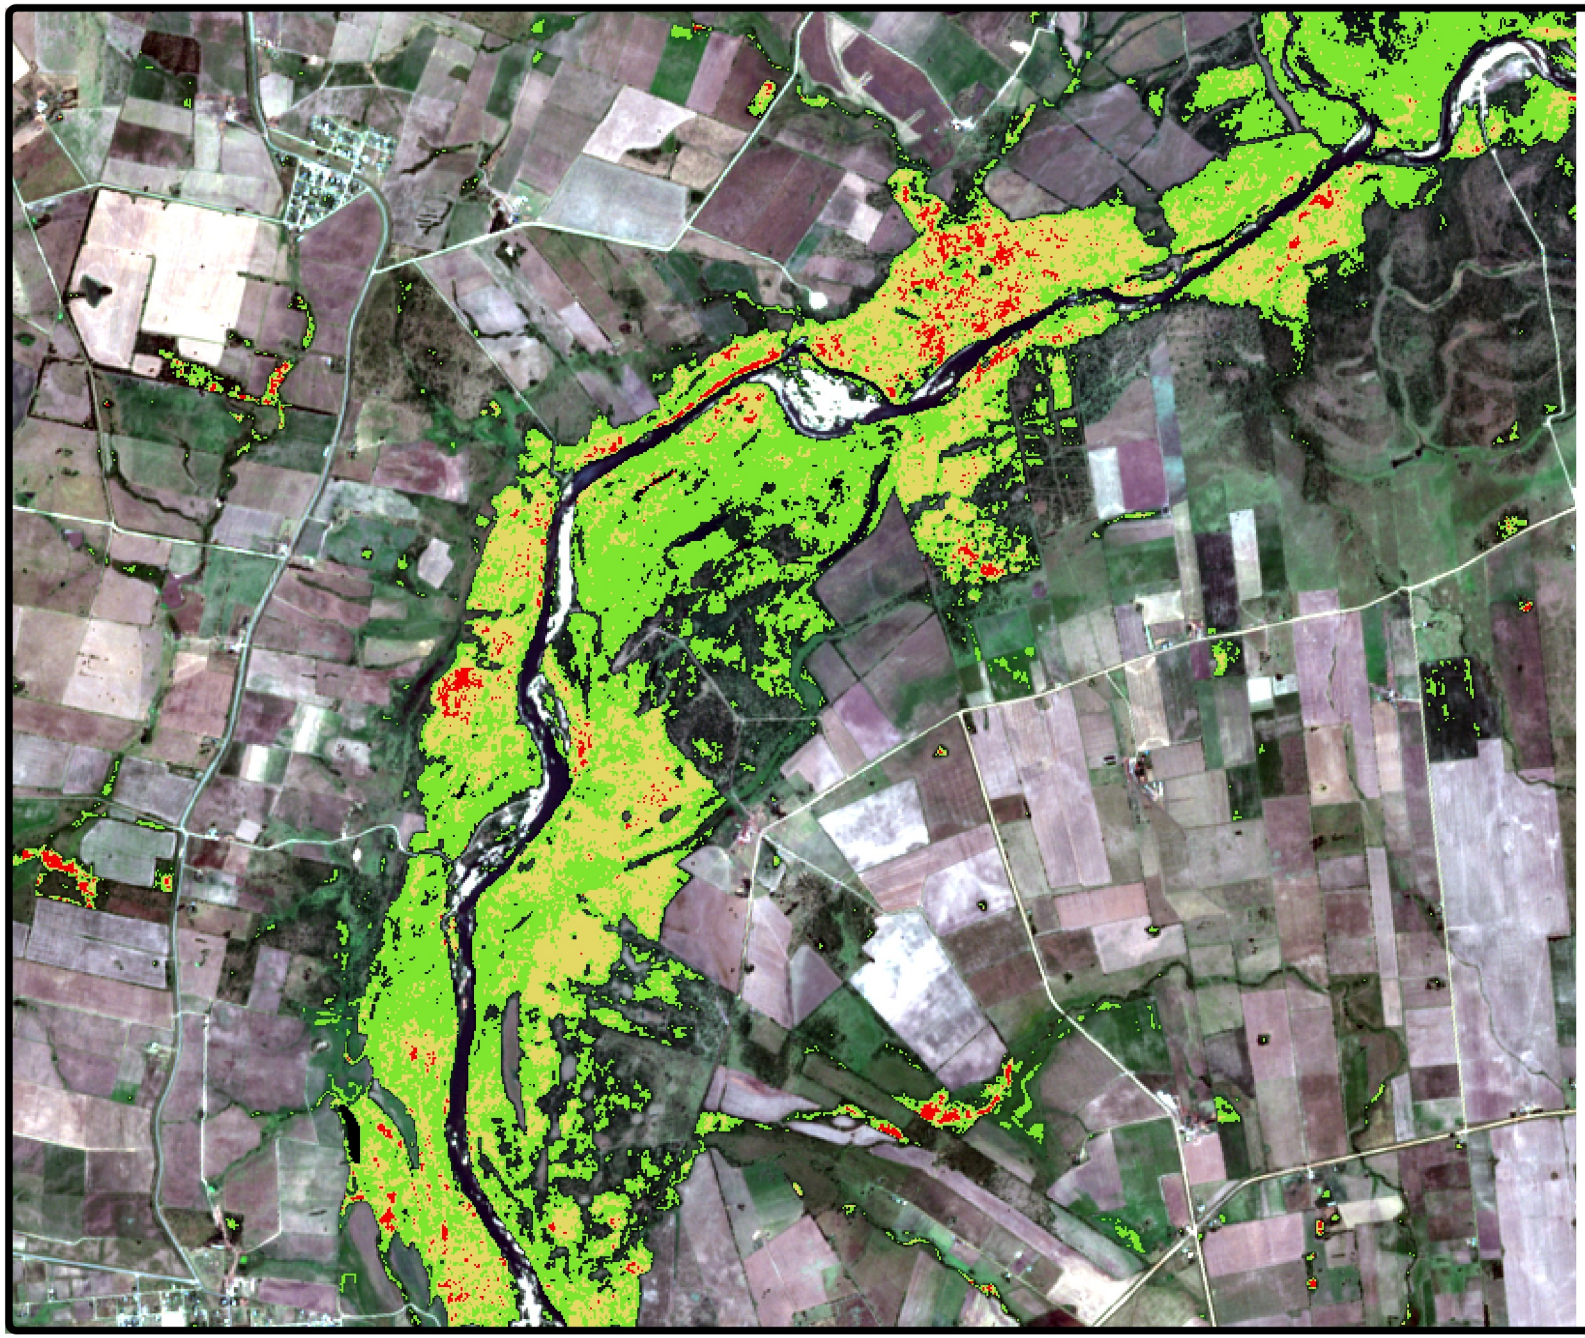

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 84)

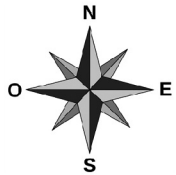

Referencias

NDVI 84 Enero 2018

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

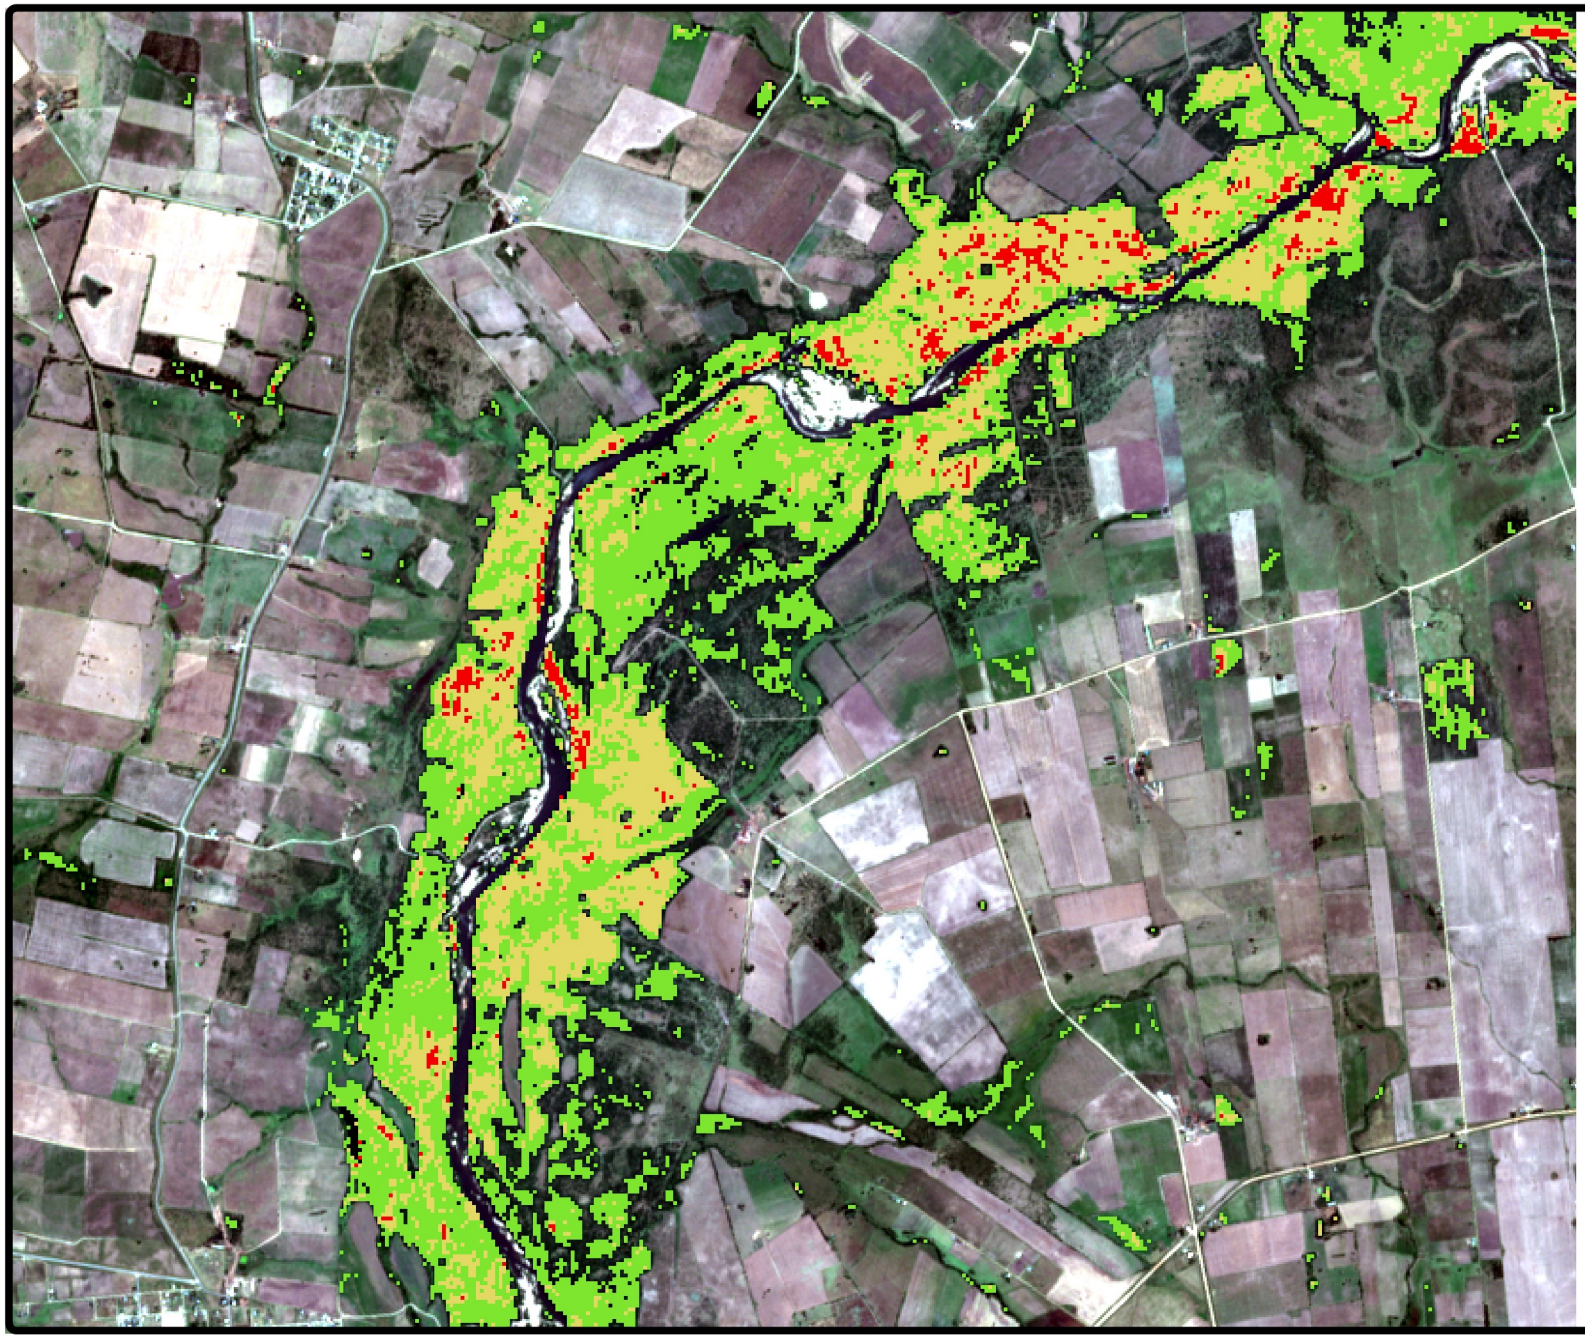

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 65)

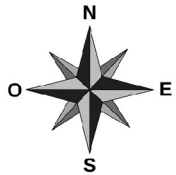

Referencias

NDVI 65 Enero 2018

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

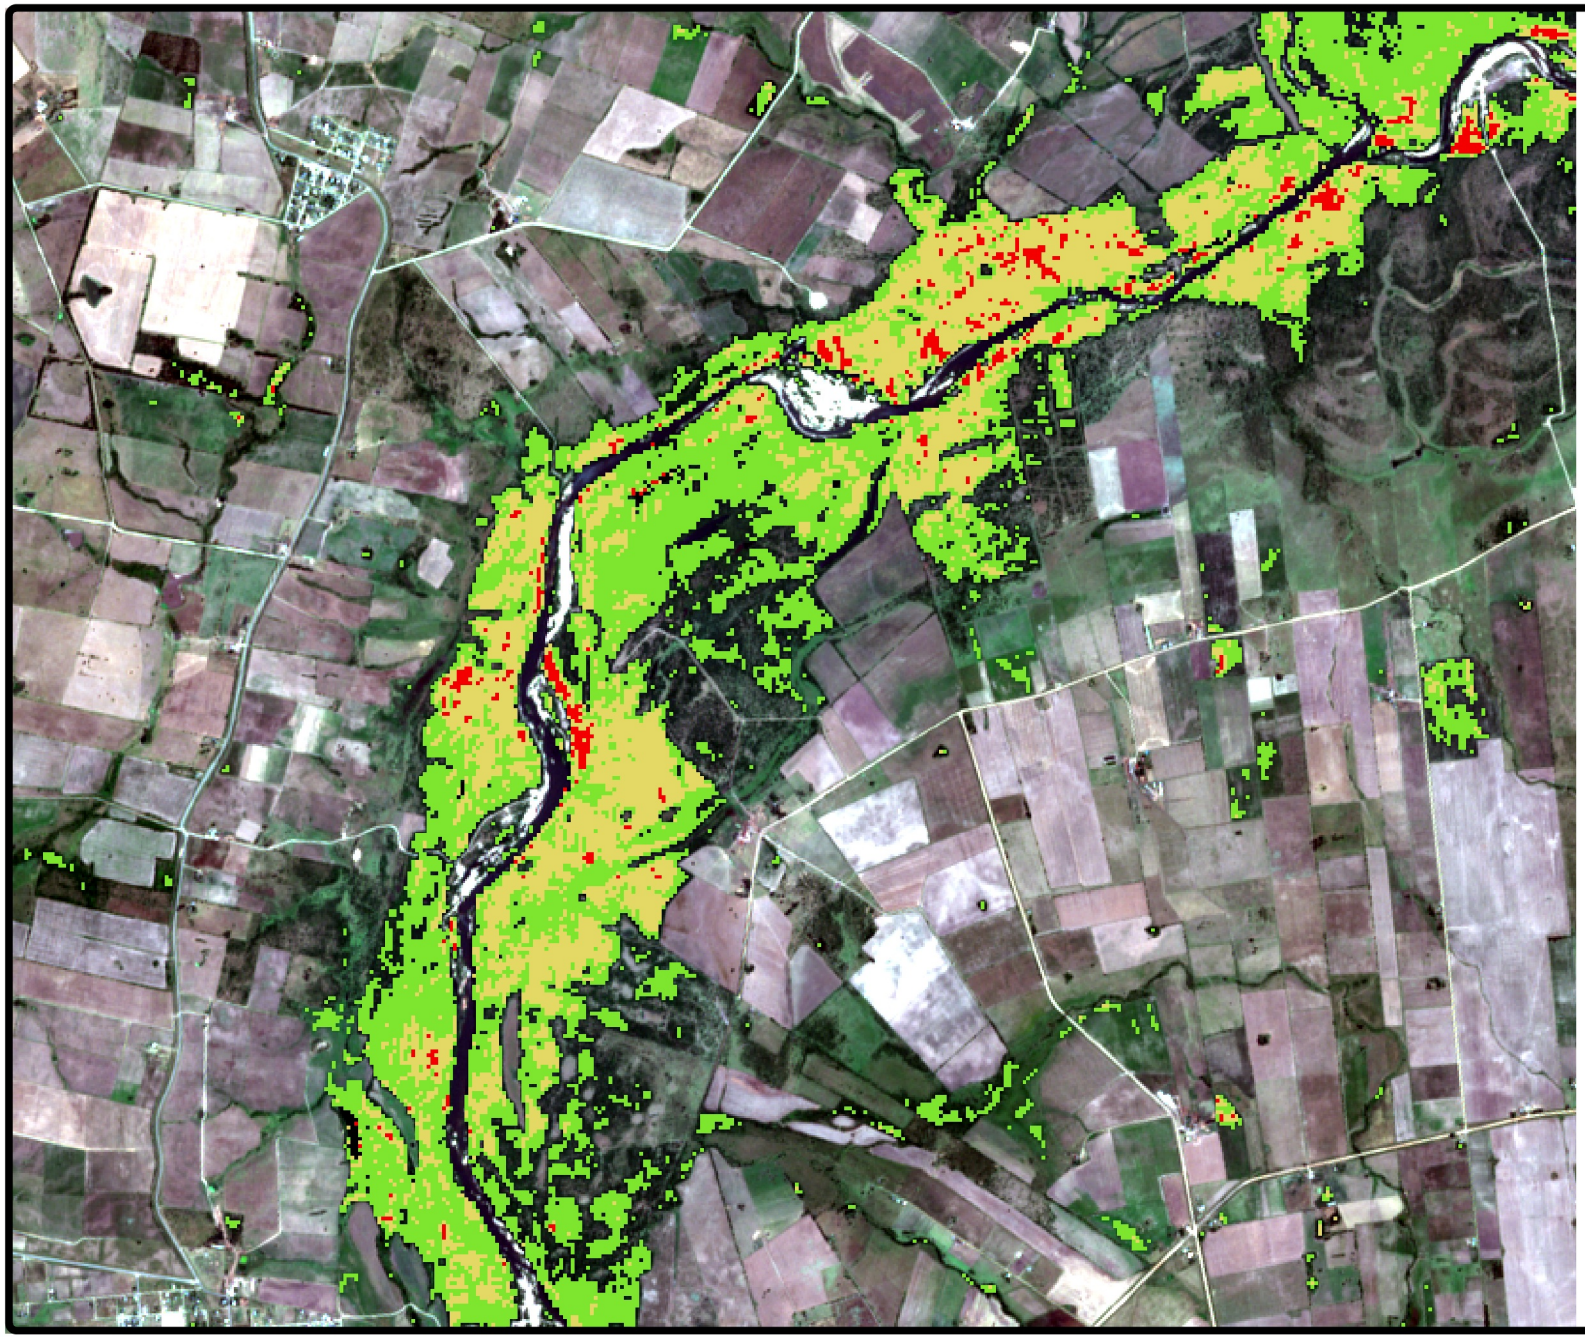

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 75)

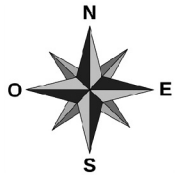

Referencias

NDVI 75 Enero 2018

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

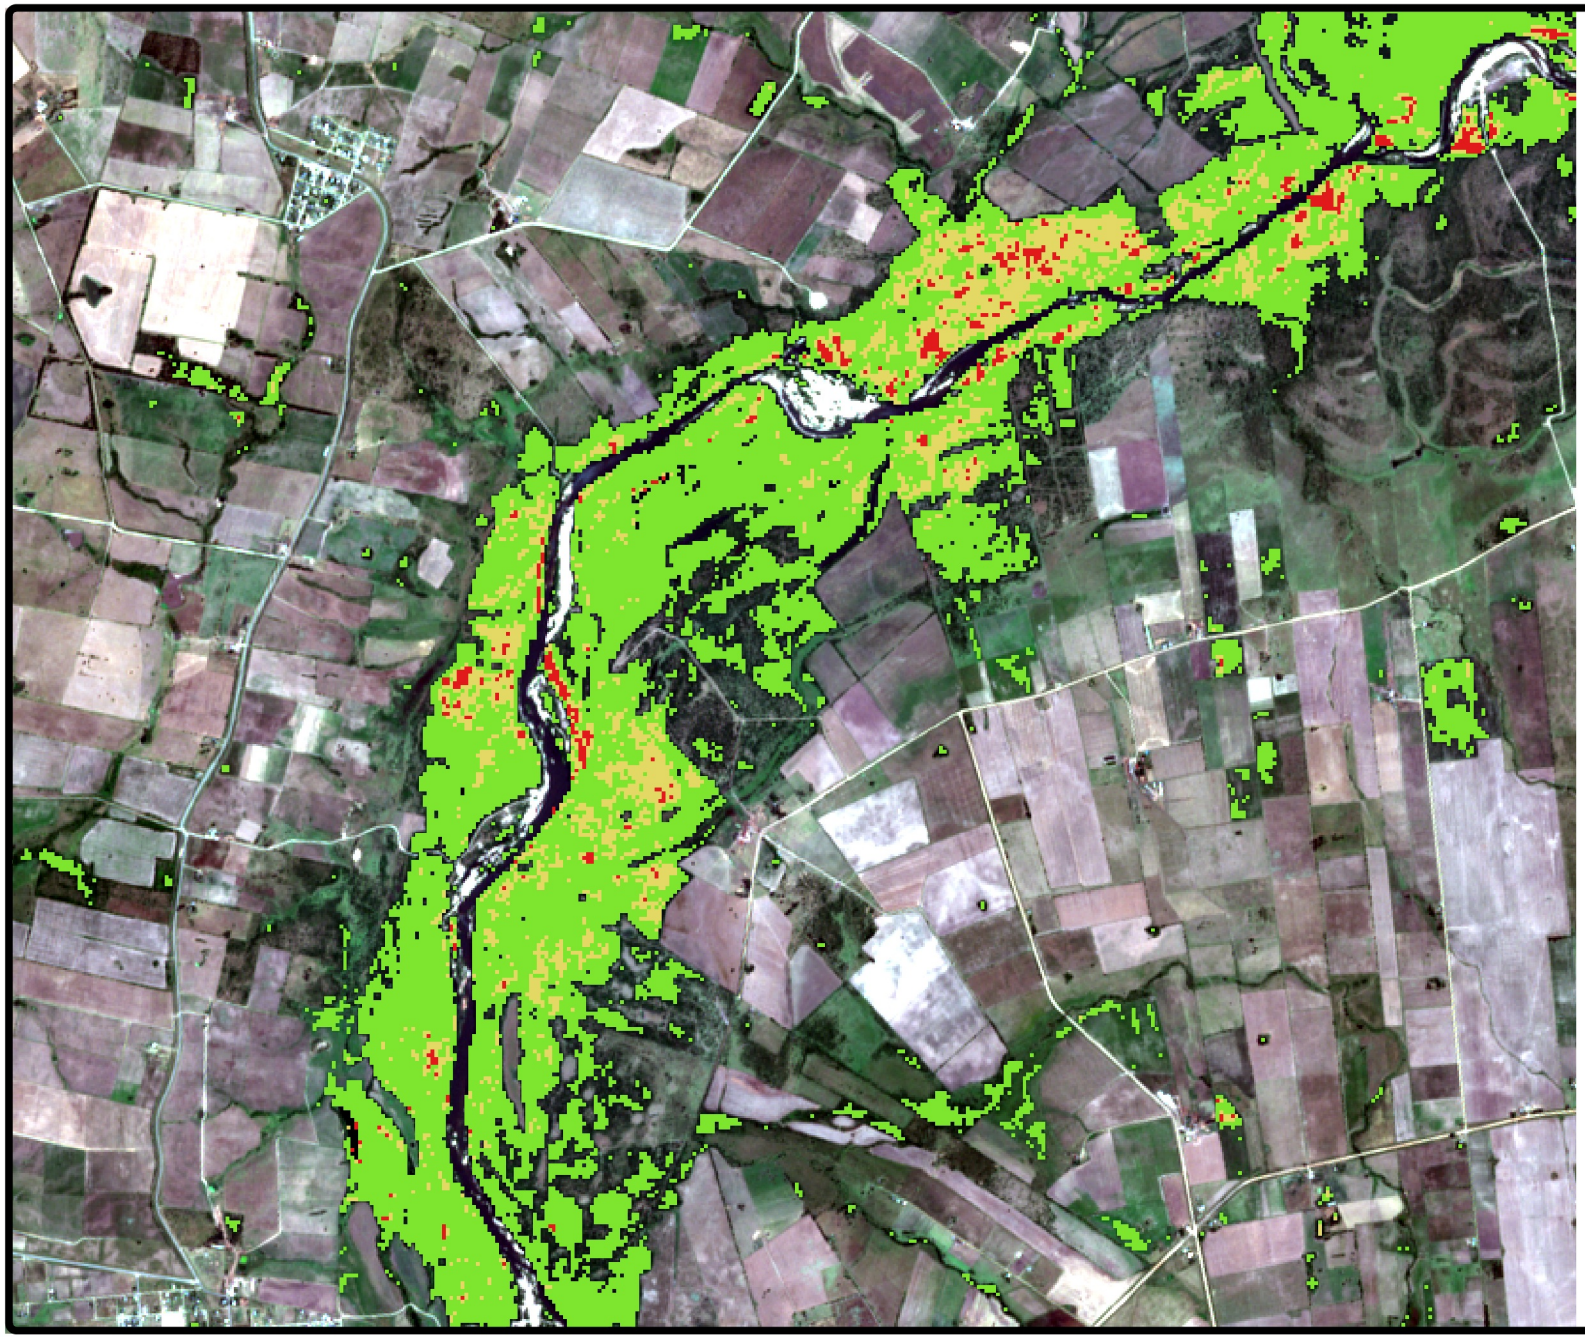

Representación visual Índice de Vegetación de Diferencia Normalizada (NDVI 8a5)

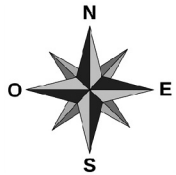

Referencias

NDVI 8a5 Enero 2018

- Ausencia de invasoras
- Zona de confusión
- Muy afectado por invasoras

Escala: 1:40.000

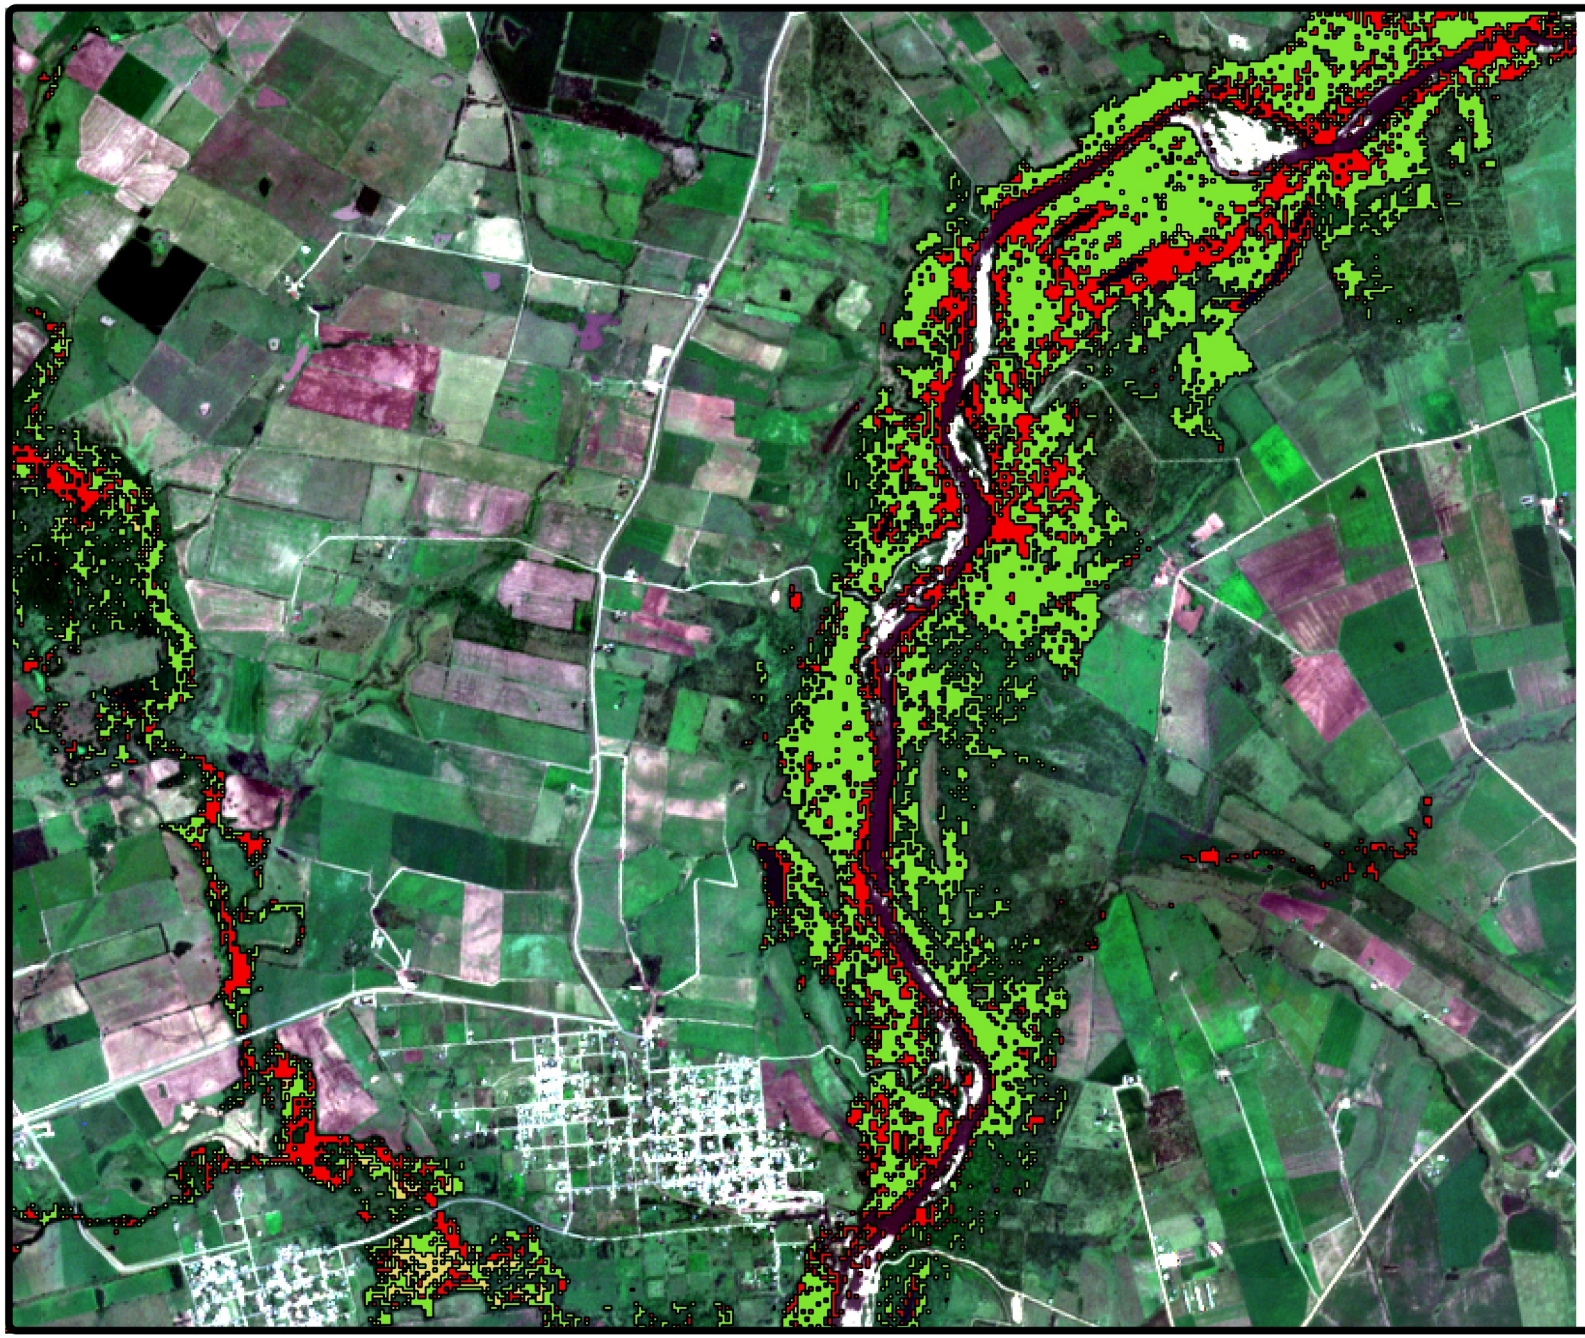

Presencia de especies invasoras en Bosque Nativo

(Clasificación Supervisada
Sentinel 2 enero 2017, 20 metros)

N
O E
S

Referencias

- Ausencia de invasoras
- Parcialmente afectado
- Muy afectado por invasoras

Escala: 1:40.000

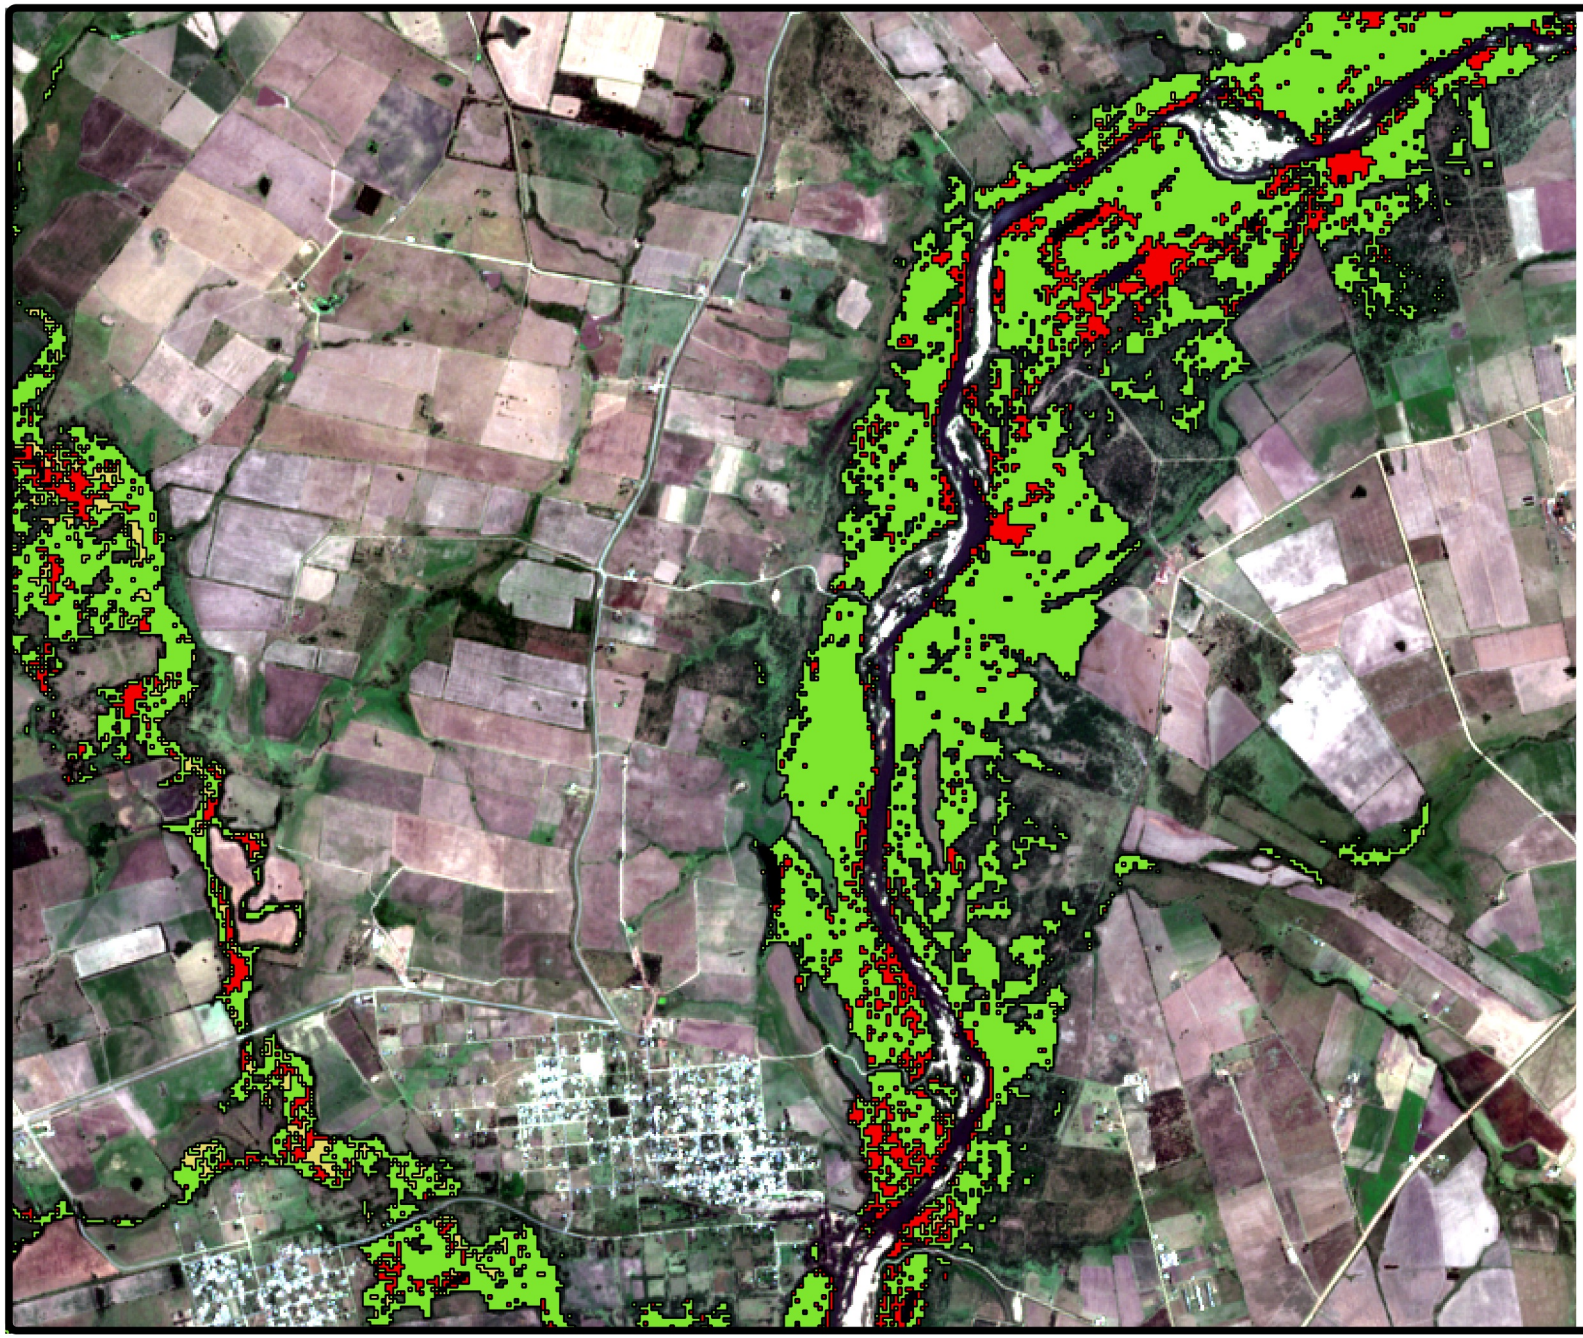

Presencia de especies invasoras en Bosque Nativo

(Clasificación Supervisada
Sentinel 2 enero 2018, 20 metros)

N
O E
S

Referencias

- Ausencia de invasoras
- Parcialmente afectado
- Muy afectado por invasoras

Escala: 1:40.000