

Universidad Pública de Navarra

**ESCUELA TECNICA SUPERIOR
DE INGENIEROS AGRONOMOS**

Nafarroako Unibertsitate Publikoa

**NEKAZARITZAKO INGENIARIEN
GOI MAILAKO ESKOLA TEKNIKOA**

**ANÁLISIS MULTITEMPORAL DE UNA SERIE DE IMÁGENES SENTINEL-1 Y
DETECCIÓN DE CAMBIOS DEL USO DE SUELO PARA LA EVALUACIÓN DE LA RESERVA
ECOLÓGICA MANGLARES CHURUTE Y SUS ALREDEDORES EN
GUAYAS-ECUADOR**

presentado por

DIANA VÉLEZ ALVARADO *(e)k*

aurkeztua

**MÁSTER EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y TELEDETECCIÓN
MASTERRA INFORMAZIO SISTEMA GEOGRAFIKOETAN ETA TELEDETEKZIOAN**

Mes, Año / *Junio, 2019*

AGRADECIMIENTOS

A Dios, a mis padres Andrea y Agustín, a mi mamita Blanca, a mis hermanos Wendy, Marlene, Ezequiel e Israel, por su apoyo incondicional en las decisiones que he tomado en la vida, a los Vélez y Alvarado por estar pendiente de mí. A los hermanos de la Iglesia "El Tabernáculo Plenitud" por sus oraciones.

A la Fundación Carolina, que mediante su programa de becas me brindo la oportunidad de seguir formándome profesionalmente. A mi tutor Jesús, por valorar el esfuerzo, por toda la ayuda brindada y a animarme a seguir adelante para alcanzar este objetivo. A Josían, por sus sugerencias en el script. A los amigos y profesores del MUSIGT, fue una dicha conocerlos.

A Ronald, por su colaboración en todos los aspectos y sugerencias en este trabajo desde que se lo comenté y a Sandrita por leerlo; son unos amigos excepcionales.

A Trivi, el hermano que la vida me dio, a Alejandro y al equipo de Ilimit Consult por el trabajo de campo. Al ing. Luis y Carlos por la información proporcionada.

Al Ec. Nicanor por su aprecio, ayuda durante el proceso de solicitud de la licencia de estudios y por todo su apoyo. A mis amigos (as) de DIRDRA y en especial a Mariuxi por defender mi espacio a capa y a espada. A Rocío por venir a visitarme y traerme cosas de mi lindo Ecuador.

A mis amigos pichuleros y en especial a Marlene, que aunque hayan pasado muchos años, la amistad se conserva. A mi Robin que ha sido fundamental durante todo este proceso de estudios, por animarme, apoyarme, por soportarme, por escucharme y por todo lo bueno de la vida y a sus padres también por estar pendiente.

A Karlita, Jacqui, por ser unas amigas del uno, a Jhon por formar parte de la familia, a Vanesa por recibirme muy bien en Granada, y la lista sigue...

Simplemente muchas gracias a todos.

Resumen

El manejo de áreas naturales protegidas administradas por el Estado requiere de información oportuna, veraz y de bajo costo. El territorio que rodea a un área protegida es parte de la atención de los planes de gestión de cada unidad de conservación, porque las actividades desarrolladas en estas zonas pueden influir en la efectiva conservación de los recursos naturales. Determinar los tipos de uso del suelo del área que rodea a un área protegida con medios convencionales resulta costoso en términos económicos y humanos, demandando recursos financieros con los que generalmente no cuentan las entidades de conservación.

Este estudio propone como herramienta de trabajo de bajo costo, el uso de imágenes radar Sentinel-1, los lenguajes de programación y los sistemas de información geográfica de libre acceso para elaborar los mapas preliminares antes de ejecutar las medidas de validación y verificación que se deben aplicar con el uso de cualquiera de los métodos disponibles. Para determinar los tipos de uso del suelo, comparar los cambios de uso con tres años de diferencia y hacer un análisis multitemporal de los cultivos se utilizaron imágenes Sentinel-1, disponibles desde el año 2014, QGIS y el lenguaje de programación R. Para la validación y verificación de campo se contó con visitas realizadas por personal técnico.

Como unidad de trabajo se utilizó la Reserva Ecológica Manglares Churute, área natural protegida de 50.000 ha, ubicada en el centro occidental de Ecuador. Se analizaron los usos de suelo a 1 km de distancia del perímetro y en un área de 70.000 ha de la llanura aluvial en la que se encuentra. Se determinó que entre los años 2015 y 2018 hubo un incremento del área ocupada por camaroneas y por caña de azúcar a 1 km de distancia del perímetro, usos del suelo que reemplazaron a los cultivos de arroz y otros usos como pasto y matorral. Se concluye que es posible elaborar mapas de cambios de uso del suelo y de estacionalidad, a bajo costo, utilizando herramientas de acceso libre y con un margen de error bajo.

Palabras clave: SIG, teledetección, cambios de uso de suelo, áreas naturales protegidas, Sentinel-1, Ecuador.

Abstract

The management of natural protected areas administered by the State requires timely, accurate and low-cost information. The territory surrounding a protected area is part of the attention of the management plans of each conservation unit, because the activities developed in these areas can influence the effective conservation of natural resources. Determining the types of land use of the area surrounding a protected area with conventional methods is costly in economic and human terms, demanding financial resources with which conservation departments do not usually count.

This study proposes as a low-cost work tool the use of Sentinel-1 radar images, programming languages and free access Geographic Information Systems (GIS) to prepare preliminary maps before executing the validation and verification measures that should be applied with the use of any of the available methods. For determining the types of land use, comparing land use changes with a difference of three years, and making a multitemporal analysis of the crops, there were used Sentinel-1 images, available since 2014, also there were used QGIS and the programming language R. Validation and field verification were carried out by technical personnel on field.

As a unit of work, it was used the Churute Manglares Ecological Reserve, a 50,000 ha natural protected area, located on the center western of Ecuador. It was analyzed the land use 1 km away from the perimeter and in an area of 70,000 ha of the alluvial plain in which it is located. It was determined that between 2015 and 2018 there was an increase in the area occupied by shrimp farms and by sugarcane 1 km away from the perimeter, land uses that replaced rice crops and other uses such as pasture and scrub. It is concluded that it is possible to prepare maps of changes in land use and seasonality, at low cost, using free access tools, and with a low margin of error.

Keywords: GIS, remote sensing, land use change, protected natural areas, Sentinel-1, Ecuador.

Índice

1. INTRODUCCIÓN	6
1.1. Los sistemas de información geográfica y la teledetección	6
1.2. Objetivos	8
2. MATERIAL Y MÉTODOS	9
2.1. Área de estudio	9
2.2. Imágenes Sentinel -1	10
2.3. Procesamiento de imágenes Sentinel 1	11
2.4. Clasificación supervisada	13
2.5. Evaluación de los resultados	21
2.6. Detección de cambios de uso del suelo	23
3. RESULTADOS Y DISCUSIÓN	24
3.1. Matrices de correlación	24
3.2. Análisis de separabilidad	27
3.3. Clasificación supervisada	31
3.4. Detección de cambios de uso del suelo	34
4. CONCLUSIONES	37
5. BIBLIOGRAFÍA	38
ANEXOS	41

Índice de figuras

Figura 1. Principales mecanismos de retrodispersión (Larrañaga & Alvarez-Mozos, 2016a)	7
Figura 2. Ubicación del área de estudio	9
Figura 3 . Modelo gráfico para el recorte de las imágenes	11
Figura 4. Modelo gráfico para el procesamiento de las imágenes.	12
Figura 5. Áreas de entrenamiento	14
Figura 6. Cultivo de arroz	15
Figura 7. Cultivo de banano	15
Figura 8. Bosque	16
Figura 9. Cultivo de cacao	16
Figura 10. Cultivo de camarón.....	17
Figura 11. Cultivo de caña de azúcar	18
Figura 12. Cultivo de palma africana	18
Figura 13. Manglar	19
Figura 14. Matorral	19
Figura 15. Herbazal	20
Figura 16. Estructura del algoritmo Random Forest	21
Figura 17. Delimitación zona buffer alrededor de la reserva	23
Figura 18. Combinación RGB, para el 12-ene, 18-may, 21-sep.....	24
Figura 19. Combinación RGB, para el 17-feb, 17-jun, 03-oct	25
Figura 20. Curvas temporales de retrodispersión del camarón: VHdb, VVdb y qdb.....	25
Figura 21. Curvas temporales de retrodispersión del arroz: VHdb, VVdb y qdb.....	26
Figura 22. Curvas temporales de retrodispersión de la caña de azúcar: VHdb, VVdb y qdb.....	26
Figura 23. Curvas temporales de retrodispersión del banano: VHdb, VVdb y qdb.....	26
Figura 24. Análisis separabilidad arroz.....	27
Figura 25. Análisis separabilidad banano	28
Figura 26. Análisis separabilidad bosque	29
Figura 27. Análisis separabilidad cacao	29
Figura 28. Análisis separabilidad camarón	30
Figura 29. Análisis separabilidad caña de azúcar, palma y manglar.....	31
Figura 30. Ranking de importancia de valores.....	32
Figura 31. Resultado de la clasificación	33
Figura 32 Usos de suelo 2015-2018.....	34
Figura 33 Cambios de uso de suelo 2018	35

Índice de tablas

Tabla 1. Características de las imágenes Sentinel 1 en modo operacional IW	10
Tabla 2. Parámetros del modelo gráfico	13
Tabla 3. Áreas (ha) de entrenamiento	13
Tabla 4. Estructura de una matriz de confusión (clasificación)	22
Tabla 5. Clasificación del estadístico Kappa.....	23
Tabla 6. Correlación entre enero, mayo y septiembre	24
Tabla 7. Matriz de confusión.....	33
Tabla 8. Fiabilidad del usuario y productor	34
Tabla 9. Cambios de uso de suelo 2015-2018	35

1. INTRODUCCIÓN

El Sistema Nacional de Áreas Protegidas del Ecuador alberga a 56 reservas naturales, que cubren aproximadamente un 20 % del territorio nacional (Elbers, 2011); la Reserva Ecológica Manglares Churute (REMCh) forma parte de este sistema desde 1979, siendo único por la gran diversidad de ecosistemas que posee (Yanez, 1996), también está incluida en la lista de sitios Ramsar desde 1990 y actualmente se encuentra bajo la administración del Ministerio del Ambiente del Ecuador.

Uno de los aspectos más críticos en el manejo de áreas protegidas es determinar los cambios en el uso del suelo en las áreas vecinas o lo que se conoce como área de amortiguación que corresponde a la zona de transición entre los sistemas naturales y los usos intensivos de la tierra. Para el año 2015 más de la mitad (58 %) del área de amortiguación (1km) alrededor de la REMCh, estuvo ocupada por tres cultivos: arroz, banano y caña de azúcar (IEE, MAGAP, & CGSIN, 2015) que utilizan agroquímicos de distintos tipos para el control de insectos, hongos y malezas y por granjas destinadas al cultivo de camarón cuyo proceso de cría produce incrementos de salinidad del agua, el uso de químicos para el control de peces depredadores y la muerte de aves que se alimentan de camarón en las piscinas.

Un cambio de uso de suelo alrededor de la REMCh, es un motivo de preocupación por parte de sus administradores, porque puede afectar la conservación de los recursos naturales que protegen, es así que para maximizar el potencial de las áreas, quienes la administran necesitan estar al tanto de lo que ocurre a su alrededor, para tomar las decisiones correctas para el éxito de su gestión (Hockings, 2003).

Existe una propuesta de manejo para la reserva (Yanez, 1996), en la que se incluye una serie de programas para su administración y gestión, sin embargo su conservación no solo dependerá de las actividades que se realicen al interior de la reserva sino de las acciones a su alrededor que tengan influencia directa sobre ella.

Lo que se pretende con este trabajo es analizar, mediante el uso de los sistemas de información geográfica y la teledetección, si ha existido o no cambios en el uso de suelo en los alrededores de la REMCh en un período comprendido entre el 2015 y el 2018.

1.1. Los sistemas de información geográfica y la teledetección

Los SIG (Sistemas de Información Geográfica), son sistemas que integran tecnología informática, personas e información geográfica, cuya función es capturar, analizar, almacenar, editar y representar datos georeferenciados (Olaya, 2014).

La teledetección (*remote sensing*), es la ciencia y el arte de obtener información de un objeto o área, o fenómeno, mediante la adquisición de datos (imágenes), sin entrar en contacto con el mismo (Lillesand, Kiefer, & Chipman, 2015), para lo cual se capta la radiación electromagnética emitida o reflejada por la superficie terrestre en una o más regiones del espectro electromagnético (Campbell & Wynne, 2011).

Los sensores de teledetección radar trabajan en la región de las microondas (longitud de ondas en cm), emiten un pulso de radiación hacia el terreno y reciben el eco o retorno del que se extrae información sobre los objetos presentes en la trayectoria del pulso, su posición y algunas propiedades de interés; este eco se produce por un fenómeno denominado retrodispersión.

La retrodispersión varía en función de la frecuencia del sensor, de su ángulo de incidencia y polarización (HH, HV, VH, VV); se puede interpretar en función de tres principales mecanismos: superficial, doble rebote y volumen (figura 1).




Figura 1. Principales mecanismos de retrodispersión (Larrañaga & Alvarez-Mozos, 2016a)

Por lo general, la *retrodispersión superficial* ocurre en superficies lisas, superficies de aguas en calma, en donde el flujo de energía se comporta de forma especular, la señal no retorna a la antena por lo que en la imagen se visualizan zonas en colores oscuros y con poco brillo. En la *retrodispersión de doble rebote* (zonas urbanas, y en cubiertas forestales a nivel de tronco), se produce cuando el pulso incide sobre una superficie lisa y el pulso reflejado vuelve a incidir sobre otra superficie perpendicular a la anterior produciendo un retorno intenso en la dirección del sensor, en estos casos la señal es muy intensa por lo que en la imagen se visualizan zonas muy brillantes. El mecanismo de *retrodispersión de volumen*, es un fenómeno intermedio entre los dos anteriores, se presenta en zonas forestales cultivos densos, superficies rugosas, a la antena retorna una parte de la señal que se emite en función de las características geométricas y dieléctricas de las cubiertas, en la imagen se visualizan en tonos grises¹.

Al ser sensores activos, generan su propia energía, por lo tanto pueden obtener imágenes tanto de día como de noche y la nubosidad no afecta su capacidad de observación, teniendo así una cobertura continua de la tierra lo que facilita su uso en zonas en donde la nubosidad es constante (Woodhouse, 2006). El uso de imágenes radar ha tenido éxito en muchos campos de aplicación, entre ellos el mapeo cobertura y uso de suelo, geología, tipos de hielo marino, ríos y lagos (Lillesand et al., 2015; Skriver, 2007). La misión Sentinel 1 compuesta por una constelación de dos satélites: Sentinel-1A, lanzado en abril del 2014 y Sentinel 1-B, lanzado en abril del 2016, proporciona imágenes de tipo radar en la banda-C (ESA, 2019), lo que permite su uso global en la detección de cambios, monitoreo de áreas con vegetación, hielos, océanos, navegación marítima.

En zonas tropicales y húmedas en donde la cobertura nubosa es constante como en la zona de estudio, el uso de series temporales de imágenes Sentinel-1, han contribuido con el monitoreo del sector agrícola, forestal (Del'Arco Sanches et al., 2018) y acuícola (Ottinger et al., 2017).

¹ Apuntes de clases. Teledetección RADAR y LiDAR, MUSIGT 2018-2019

1.2. Objetivos

El objetivo general de este trabajo consiste en analizar los cambios de uso de suelo en los alrededores de la Reserva Manglares Churute (REMCh) para su evaluación, además de los siguientes objetivos específicos.

- Ejecutar el procesamiento de las imágenes Sentinel-1 en modo *Interferometric Wide Swath Mode (IW)* y nivel 1.5 *Ground Range Detected (GRD)*.
- Realizar la clasificación supervisada mediante el algoritmo Random Forest y evaluar sus resultados.
- Determinar los cambios de uso de suelo entre el 2015 y 2018.
- Interpretar cómo los cambios en el uso del suelo pueden modificar la conservación de recursos naturales de la REMCh.

2. MATERIAL Y MÉTODOS

2.1. Área de estudio

El área de estudio (figura 2) comprende aproximadamente 123.000 hectáreas, de las cuales 50.000 hectáreas pertenecen a la REMCh, ubicada en el cantón Naranjal (zona continental) y en el cantón Guayaquil (islas) en la provincia del Guayas, en Ecuador. Entre los cultivos que predominan en el área están: caña de azúcar industrial (25%), arroz (24%), camaronera (14%), banano (9%), cacao (4%), palma (1%), en menor proporción, los pastos, maíz, teca, y vegetación herbácea y arbustiva (matorral).

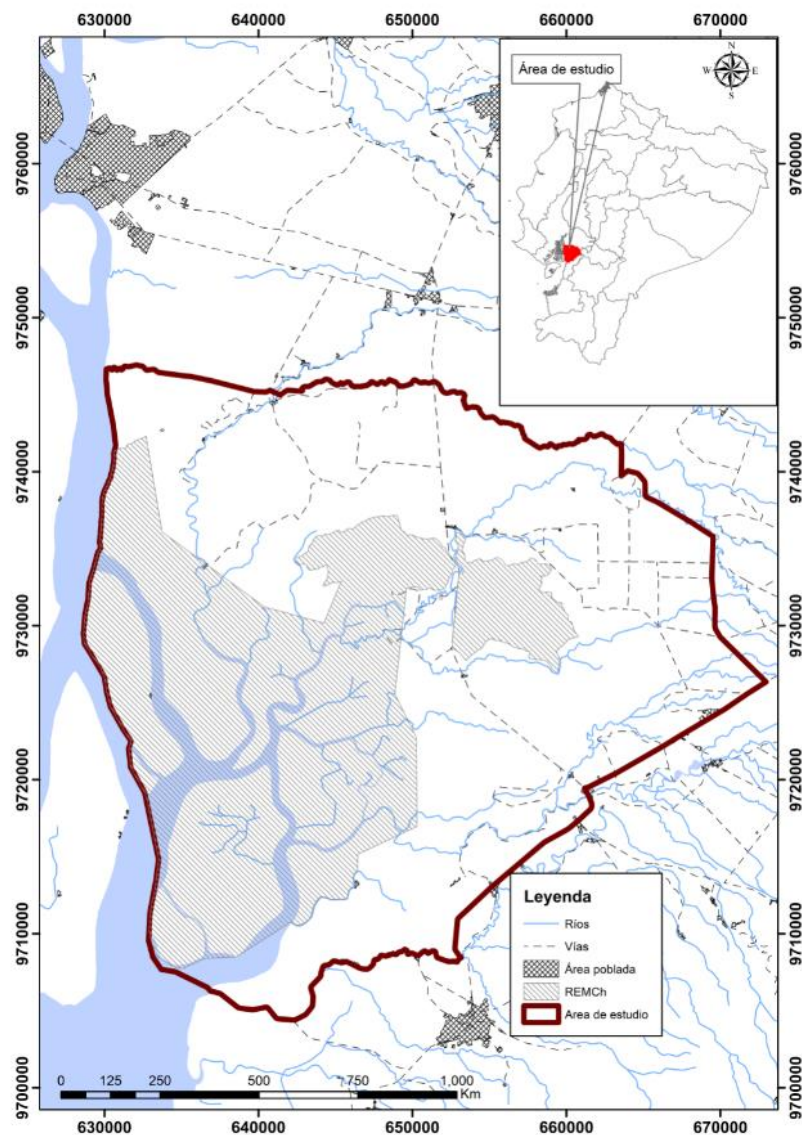


Figura 2. Ubicación del área de estudio

La REMCh se encuentra en una llanura fluvio-marina, con pendiente menor a 5 % de un área conocida como Cuenca Baja del Río Guayas que se extiende desde el estuario del río Guayas, al Oeste, hasta el piedemonte de la cordillera occidental de los Andes, al Este.

Esta zona forma parte de cinco subsistemas hidrográficos que la drenan: Jujan, Chimbo - Yaguachi, Taura - Boliche - Bulubulu, Churute y Cañar. Estos ríos inundaban la planicie, durante la estación lluviosa (diciembre a marzo) de la zona costera del Ecuador, hasta que el estado ecuatoriano construyó un sistema de control de inundaciones que opera desde el año 1997.

En el extremo oeste de la Cuenca Baja y antes de que los ríos Taura, Churute y Cañar descarguen en el estuario del río Guayas, se encuentra la REMCh. En su interior se conserva bosque de manglar, bosque seco, bosque húmedo de neblina y vegetación acuática (Navarrete, 2000). La REMCh protege tres importantes ecosistemas: la Laguna El Canclón, la Cordillera de Churute y los remanentes de manglar (ECOLAP & MAE, 2007).

En estos variados hábitats existen distintas especies de mamíferos, aves, anfibios, reptiles e invertebrados endémicos de la región seca del oeste de Ecuador y Perú. Las especies estuarinas más comunes son: mejillones (*Mytella guayanensis*), el cangrejo rojo (*Ucides occidentalis*), ostiones (*Cassostrea columbiensis*), que son la principal fuente de ingresos económicos de pescadores artesanales (ECOLAP & MAE, 2007; Yanez, 1996) y también la operación de granjas destinadas al cultivo de camarón blanco (*Penaeus vannamei*), algunas de las cuales existen desde antes de la creación de la REMCh. Otras de las actividades económicas es la agricultura principalmente de arroz, la ganadería en sus alrededores y el ecoturismo.

Desde la construcción y operación (1997) del sistema de control de inundaciones que minimiza los riesgos de daños en los diferentes usos del suelo alrededor de la REMCh, el área de amortiguación del área protegida ha sufrido cambios. Antes del año 1997, la parte septentrional y oriental del sector norte de la REMCh estaba cubierta principalmente por pastos naturales que eran aprovechados por una ganadería extensiva. Posteriormente ha sido ocupada por distintos usos del suelo, alguno de los cuales (como el cacao y pastos naturales) son beneficiosos para los objetivos de conservación de la biodiversidad de la REMCh y otros (como el cultivo de arroz y la acuicultura del camarón) en cambio, representan una amenaza y para lo cual se requiere diseñar estrategias de manejo consensuado con los propietarios.

2.2. Imágenes Sentinel -1

La descarga de las imágenes Sentinel-1, se realizó desde la página de la ESA (Agencia Espacial Europea) Copernicus Open Acces Hub: <https://scihub.copernicus.eu/dhus/#/home>, previo registro. Se descargaron 12 imágenes Sentinel 1A y 1B, en modo *Interferometric Wide Swath Mode (IW)* y nivel 1.5 *Ground Range Detected (GRD)*, con polarizaciones VH y VV; sus características se detallan en la siguiente tabla (Torres et al., 2012).

Tabla 1. Características de las imágenes Sentinel 1 en modo operacional IW

Parámetro	Interferometric Wide-swath mode (IW)
Polarización	Dual (HH+HV, VV+VH)
Rango del ángulo de incidencia	31° - 46°
Resolución en azimuth	< 20 m
Resolución en ground range	< 5 m
Number of looks	1 x 5
Ancho de pasada	> 250 km
Ruido máximo equivalente Sigma cero (NESZ)	-22dB
Estabilidad radiométrica	0.5 dB (3σ)
Precisión radiométrica	1 dB (3σ)
Error de fase	5°

2.3. Procesamiento de imágenes Sentinel 1

Las imágenes Sentinel-1 se encuentran en formato GRD y en unidades de amplitud, tanto para la polarización en VH como en VV; el procesamiento consiste en reducir el moteado, correcciones radiométricas, geométricas, topográficas y transformación de unidades lineales a decibelios.

El procesamiento de estas, se realizó mediante el software SNAP² (*Sentinel Application Platform*), desarrollado por la Agencia Espacial Europea para el proceso y análisis de imágenes satelitales provenientes de la familia Sentinel.

Para ello se crearon dos modelos gráficos: uno para realizar el recorte de las imágenes en la zona de estudio (figura 3), y el otro para el procesado masivo de todas las imágenes (figura 4).




Figura 3 . Modelo gráfico para el recorte de las imágenes

Recorte y lectura de las imágenes

Mediante el modelo gráfico indicado en la figura 3, se realizó el recorte masivo de todas las imágenes del área de estudio. Una vez recortadas fueron procesadas en secuencia hasta obtener las ideales para realizar los análisis correspondientes.

Corrección de la órbita

Aunque las imágenes disponen de los datos de orbita, estos suelen ser aproximados dado que se calculan en tiempo real, por lo tanto, para garantizar una corrección geométrica precisa, es necesario descargar los datos orbitales reprocesados, que suelen estar disponibles días después de la generación de la imagen.

Calibración de las imágenes a β^0

En este punto se transforma los niveles digitales a unidades de coeficiente de retrodispersión β^0 , magnitud que normaliza la sección equivalente radar (RCS) la cual representa la capacidad de un objeto de retrodispersar el pulso de radiación recibido.

Filtrado de moteado

Las imágenes radar se ven afectadas por una distorsión radiométrica denominada moteado (efecto sal y pimienta), que introduce variabilidad en los valores individuales de cada pixel lo que dificulta su interpretación y posterior análisis. Para reducirlo se han desarrollado distintos filtros que tratan de reducir la varianza en zonas homogéneas a la vez que mantienen la retro dispersión de reflectores discretos (Filtro de Lee y de Frost), bordes, elementos lineales (Refined Lee, Lee Sigma e IDAN) y texturas (GammaMAP).

² <http://step.esa.int/main/download/>

Ortorrectificación

La ortorrectificación, es un paso a una proyección precisa, debe hacerse con modelos matemáticos rigurosos que tengan en cuenta la posición del sensor, la geometría de la adquisición y el relieve. El modelo empleado en este trabajo es el Range-Doppler que resuelve matemáticamente las ecuaciones del rango y del efecto Doppler para obtener la posición precisa de cada punto de la imagen (Small & Schubert, 2008).

Corrección topográfica

El relieve (la pendiente y orientación de las laderas) aunque sea leve, modifica no solo la geometría de la imagen si no su radiometría, haciendo que las laderas orientadas hacia el sensor vaya incrementando su coeficiente de retrodispersión y las laderas opuestas lo vean reducido. Este efecto limita la extracción de información de las cubiertas y el uso de estas imágenes en aplicaciones de todo tipo. Para la corrección topográfica se aplicó el método denominado *Terrain Flattening* desarrollado por Small (2011), cuyo resultado es el coeficiente de retro dispersión en unidades de γ^0 normalizado topográficamente a través del ratio entre el área en la dirección del rango y el área realmente iluminada por el pulso radar.

$$\gamma_{TF}^0 = \beta^0 \frac{A_{\beta}}{A_{R\gamma}}$$

Como ya se mencionó, el procesamiento masivo de las imágenes se realizó mediante un modelo gráfico, cuya estructura se presenta en la figura 4.

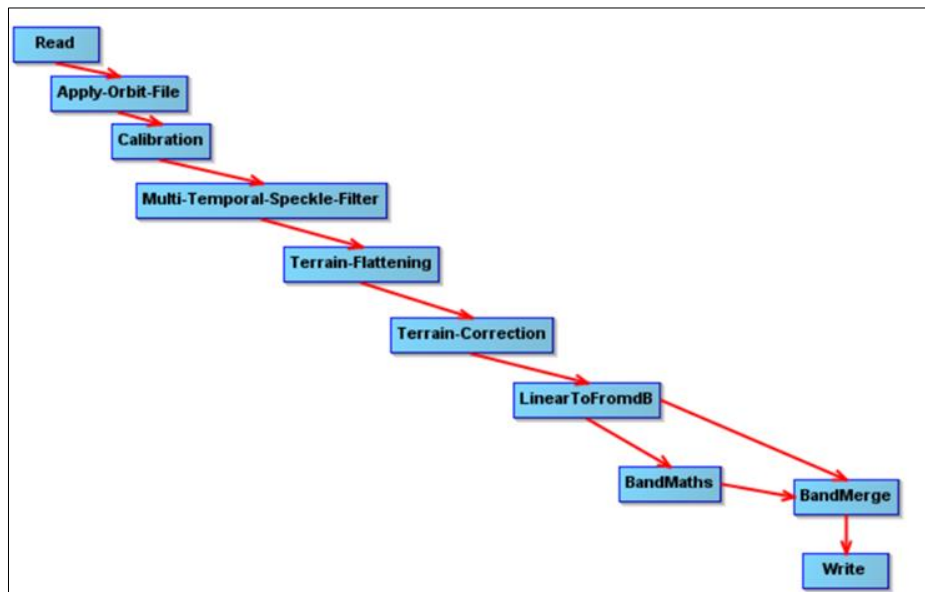


Figura 4. Modelo gráfico para el procesamiento de las imágenes.

En la siguiente tabla se presenta un resumen de los parámetros utilizados para el modelo gráfico.

Tabla 2. Parámetros del modelo gráfico

No.	Proceso	Parámetros
1	Read	Cargar la imagen
2	Apply-Orbit-File	Orbit State Vectors: Sentinel Precise (Auto Download) Polynomial Degree:3
3	Calibration	Create beta0 virtual band
4	Multi-Temporal-Speckle-Filter	Gamma Map 3 x 3
5	Terrain Flattening	Digital Elevation Model: SRTM 1Sec HGT (Auto Download) DEM Resampling Method: BILINEAR_INTERPOLATION
6	Terrain-Correction	Digital Elevation Model: SRTM 1Sec HGT (Auto Download) DEM Resampling Method: BILINEAR_INTERPOLATION Image Resampling Method: BILINEAR_INTERPOLATION Pixel Spacing (m): 10 Map Projection: UTM Zone 17, South/World Geodetic System 1984
7	Linear To From dB	Transformación de unidades lineales a dB
8	Band Maths	Cálculo del ratio de polarización cruzada $q=VH/VV$ en dB $\text{Gamma0_VH_db} - \text{Gamma0_VV_db}$
9	Band Merge	Une en un mismo archivo gamma0VH , gamma0VV y q_db

2.4. Clasificación supervisada

El método de clasificación supervisada, parte de un cierto conocimiento de la zona de estudio, lo que permite delimitar sobre una imagen áreas representativas de las distintas categorías (clases) a las que se denominarán áreas de entrenamiento. Dichas áreas sirven para entrenar al programa de clasificación en el reconocimiento de las distintas categorías, es decir, reunir un conjunto de estadísticas que describan el patrón de respuesta espectral para cada tipo de cobertura en la que la imagen será clasificada (Chuvienco, 2010; Lillesand et al., 2015).

Partiendo del conocimiento básico de la zona, levantamiento de puntos geo referenciados de cultivos, cartografía a escala 1:25.000 (IEE et al., 2015), e imágenes de Google Earth, se procedió a delimitar las áreas que comprenderán el set de entrenamiento. De estas áreas, se seleccionó aleatoriamente un 70% para realizar la clasificación, el resto se consideró para la validación de la misma. En la figura 5 se presentan las áreas de entrenamiento tanto para clasificación y validación. Se utilizaron nueve categorías para realizar la clasificación: arroz, banano, bosque, cacao, camarón, caña de azúcar, palma, manglar, y pastizales (incluye vegetación y matorral).

En la tabla 3, se presentan las clases para el conjunto de entrenamiento y validación.

Tabla 3. Áreas (ha) de entrenamiento

Clase	Area (ha)	
	Train	Test (Validacion)
Arroz	152	64
Banano	394	178
Bosque	101	32
Cacao	81	48
Camarón	596	266
Caña de azúcar	395	86
Palma	38	22
Manglar	337	158
Pastizal	7	3
Total	2101	856

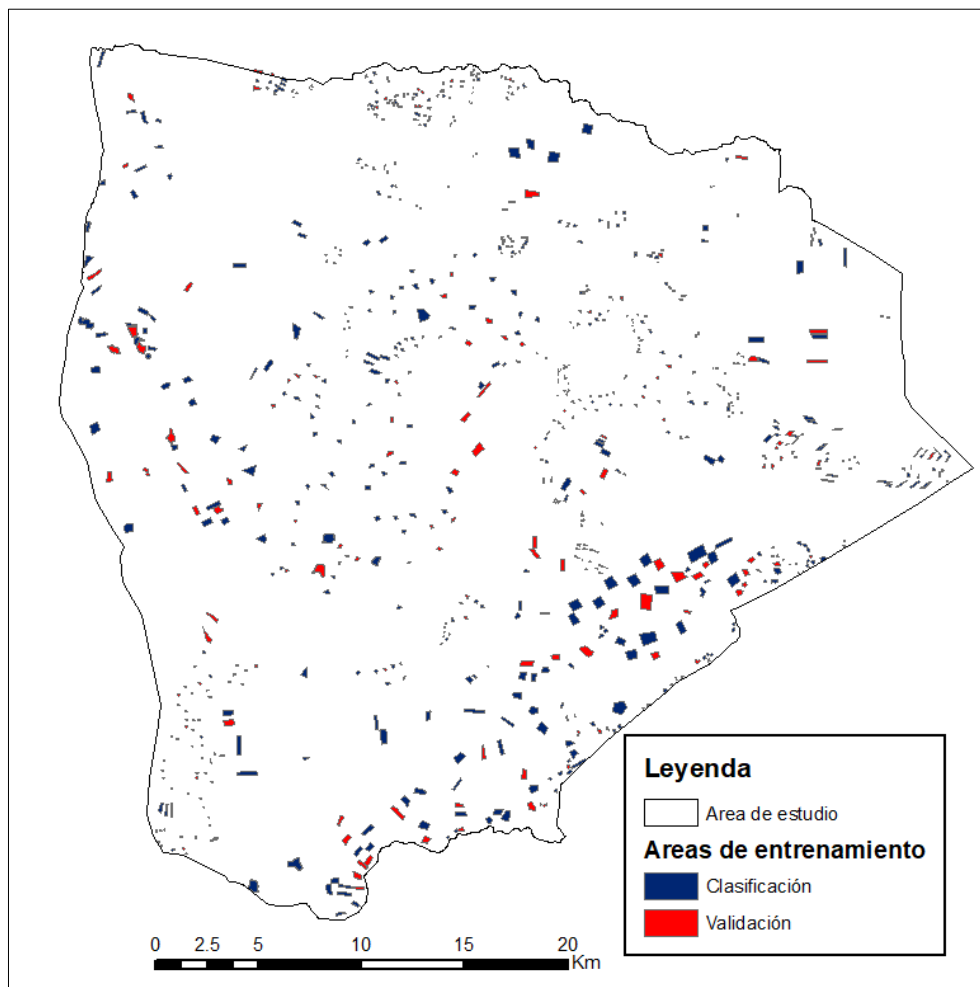


Figura 5. Áreas de entrenamiento

Descripción de clases

1.- Arroz

Es uno de los principales productos de la canasta básica en los hogares ecuatorianos. Es una gramínea que tiene entre 60 y 120 cm de altura, que se desarrolla bajo inundación, en ciclos que van entre 120 y 140 días dependiendo de la variedad. Se distinguen tres fases de desarrollo: vegetativa, reproductiva y madurez. La fase vegetativa dura de 55 a 60 días, va desde la germinación de la semilla hasta la diferenciación del primordio floral. La fase reproductiva empieza desde la formación del primordio floral hasta la emergencia de la panícula (floración) dura entre 35 y 40 días. La fase de madurez dura de 30 a 40 días, abarca desde la floración, llenado y desarrollo de los granos, hasta la cosecha. La siembra se realiza con el terreno inundado con una lámina de agua de cinco centímetros de altura, a medida que crece el cultivo, esta se va incrementando hasta los 15 cm aproximadamente; previo a la cosecha el terreno se deja secar para la realización de la misma³.

³ Arroz: <http://cultivodearrozoryzasativa.blogspot.com/>



Preparación de terrenos previo a la siembra de arroz

Desarrollo del cultivo de arroz

Figura 6. Cultivo de arroz

 Fuente: Ilimit Consult⁴

2.- Banano

El banano es el primer producto de exportación no petrolero, de Ecuador, es una planta herbácea perenne, es decir, mientras se encuentra en producción también se están desarrollando nuevas plantas que crecen a su alrededor, de las cuales el productor selecciona la más adecuada para que continúe con la propagación del cultivo. La planta alcanza una altura entre 3.5 a 7.5 metros y tiene un período de vida de 13 meses. Se distinguen las siguientes fases de desarrollo: infantil, independiente y reproductiva.

La fase infantil va desde la aparición de la yema lateral en la base de la planta madre hasta que el hijo se hace independiente de la misma, esta fase dura entre 120 a 160 días y ocurre cuando la planta madre tiene aproximadamente cinco meses. La fase independiente, está demarcada por la emisión de la primera hoja del hijo, y una vez independiente comienza a desarrollar hojas de tamaño normal. Esta fase dura entre 50 a 60 días. La fase reproductiva empieza desde el inicio de la floración hasta la cosecha del racimo (Florío de Real et al., 2012).



Lote de banano

Fruto de banano

Figura 7. Cultivo de banano

Fuente: Ilimit Consult

⁴ <https://www.ilimitconsul.com/>

3.- Bosque

La REMCh, protege los remanentes de bosque seco tropical, ecotonos importantes y el tipo de bosque húmedo existente principalmente en alturas intermedias y altas de los cerros (Yanez, 1996).



Figura 8. Bosque

Fuente: Navarrete R. (Izquierda), diario El Universo, 2019⁵ (derecha)

4.- Cacao

Llamado también 'pepa de oro' es una planta perenne, dependiendo de la variedad (CCN51, o fino de aroma) su altura oscila entre 4 y 7 metros aproximadamente. Se cultiva solo o asociado con otras especies. Su crecimiento es rápido, y la fructificación empieza entre el segundo y tercer año a partir de la siembra. La cosecha inicia cuando el fruto ha alcanzado su madurez, la cual se da por el cambio de coloración, que depende de la variedad.



Figura 9. Cultivo de cacao

Fuente: Ilimit Consult

⁵ Una reserva ecológica del Guayas rodeada de sembríos, pesca y recintos en Ecuador, <https://www.eluniverso.com/noticias/2019/05/12/nota/7323134/reserva-guayas-rodeada-sembrios-pesca-recintos-ecuador>

5.- Camarón

Es un cultivo de alto rendimiento que empezó a partir de los años 50, siendo, en Ecuador, el segundo mayor producto de exportación no petrolera después del banano. Su sistema de producción es en piscinas, se desarrolla en alrededor de cuatro meses hasta lograr el peso y las medidas deseadas. En función del sistema de producción puede variar entre 1 a 2.5 ciclos al año; entre cada ciclo se realiza el vaciado de las piscinas y su preparación para recibir a un nuevo lote de larvas las cuales se desarrollan en laboratorios, comenzando un nuevo ciclo (Palacios, 2016).



Figura 10. Cultivo de camarón
Fuente: Navarrete R. (Izquierda), diario El Comercio ⁶ (derecha)

6.- Caña de azúcar

La caña de azúcar es un producto de exportación pero en menor proporción en comparación con el banano y camarón. Es una gramínea anual, que tiene un tallo macizo de 2 a 5 metros de altura con unos 5 o 6 cm de diámetro. A los 13 meses de edad se realiza la primera cosecha, luego viene el desarrollo de la caña soca, la cual empieza después del primer corte y termina con el último en los que puede llegar hasta cinco. Posteriormente se realiza la renovación de la plantación (Ingenio San Carlos, 2013).

Tiene cuatro fases de desarrollo: emergencia, amacollamiento, rápido crecimiento y maduración. La fase de emergencia o germinación inicia a los 7 o 10 días después de la siembra, dura hasta 35 días. El amacollamiento empieza alrededor de los 35 a 40 días después de la siembra, se caracteriza por el brote de varios tallos desde la base de los tallos primarios. En la fase de rápido crecimiento se presenta una gran acumulación de materia seca y la planta alcanza su máximo índice foliar, dura entre 120 y 180 días. La maduración tiene una duración entre 60 y 90 días; en esta fase se da el proceso de síntesis y acumulación de sacarosa en los tallos de la caña.

⁶ ¿El camarón ecuatoriano es el mejor del mundo? 5 argumentos para creer que sí, diario El Comercio, 2014
<https://www.elcomercio.com/actualidad/camaron-ecuatoriano-mundo.html>



Figura 11. Cultivo de caña de azúcar

Fuente: Ilimit Consult

7.- Palma

La palma es una planta perenne cultivada para la extracción de aceite. La producción inicia a partir de los 2 a 2.5 años de edad, su altura puede llegar hasta los 20 metros. Su expansión es considerada como uno de los principales agentes de deforestación en el Ecuador⁷. En los últimos años, en la Costa ecuatoriana, el cultivo de palma africana ha sufrido pérdidas por el efecto de hongos y varias plagas de insectos que se alimentan de las hojas de la planta, por lo que su expansión alrededor de la Reserva debería ser vigilada⁸.



Cultivo de palma africana

Figura 12. Cultivo de palma africana

 Fuente: Diario El Telégrafo, 2018⁹

⁷ La palma africana se apodera silenciosamente de Ecuador, Aguilar D, 2017.

<https://es.mongabay.com/2017/10/la-palma-africana-se-apodera-silenciosamente-ecuador/>

⁸ Palmicultores solicitan al Estado declarar en emergencia al sector, diario El Telégrafo 2018

www.eltelegrafo.com.ec <https://www.eltelegrafo.com.ec/noticias/economia/4/cogollo-afectacion-palma-aceitera-ecuador>

⁹ Ibídem

8.- Manglar

El 60 % de la REMCh son manglares, es un tipo de formación vegetal siempreverde que se encuentra en las márgenes de los esteros con influencia de la marea se desarrollan en la interfaz de tierra firme hacia mar abierto y presentan un dosel cerrado que oscila entre 10 a 12 metros, vegetación típica con la presencia de raíces zancudas (MAE, 2013).



Figura 13. Manglar
Fuente Navarrete R.

9.- Pastizales, y vegetación.

La vegetación arbustiva (matorral), pertenece a una vegetación densa, de poca altura. La vegetación arbustiva seca, comprende vegetación lignificada de poca altura que pierde sus hojas en la temporada seca y en ocasiones se presentan arboles aislados dominantes. La vegetación herbácea, por lo general de tipo gramínea mantiene el verdor constante, utilizados con fines de pastoreo. La vegetación herbácea seca se encuentra de forma dispersa en toda la zona de estudio (IEE et al., 2015).



Figura 14. Matorral
Fuente: IEE et al., 2015

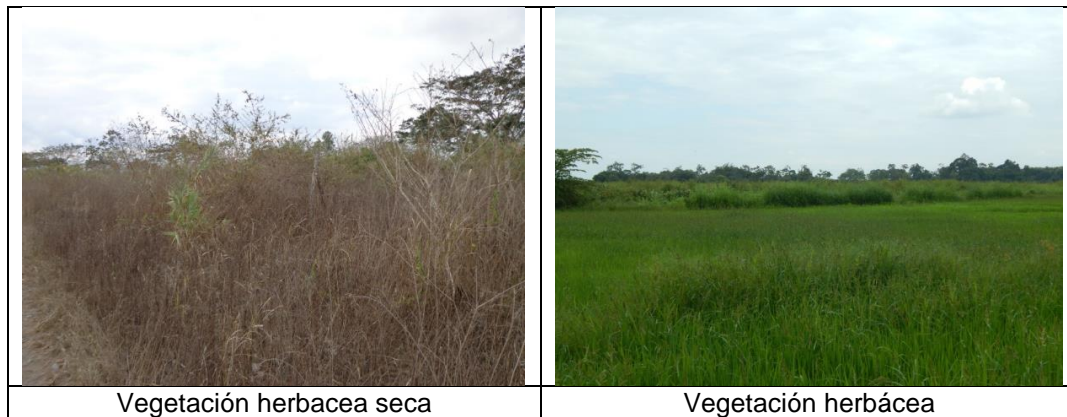


Figura 15. Herbazal
Fuente: IEE et al., 2015

Análisis de correlación, separabilidad y clasificación

Previo al proceso de clasificación de las imágenes es conveniente realizar un análisis estadístico sobre la separabilidad de las categorías seleccionadas (Chuvienco, 2010). En principio se determinó la correlación entre las imágenes las 36 imágenes (polarización VHdb, VVdb, qdb) considerando la zona de estudio mediante lenguaje en R (Hijmans, 2019), con la cual se determinará a priori la relación que existe entre las diferentes bandas en las distintas fechas.

Para evaluar la separabilidad, de entre los diferentes métodos existentes, se utilizó el algoritmo de distancia de **Jeffries-Matusita (JM)** (Swain & King, 1973), que permite cuantificar la separabilidad entre dos categorías, tomando en cuenta la distancia de los valores medios de cada clase así como la distribución de los mismos, de tal forma que se evalúa el grado de solape entre dos categorías en rangos que van entre 0 y 2 (Dabboor, Howell, Shokr, & Yackel, 2014).

$$J_{ij} = \int \left[\sqrt{p(x|\omega_i)} - \sqrt{p(x|\omega_j)} \right]^2 dx$$

Donde J_{ij} es la distancia de JM entre los pares de clases ω_i y ω_j , x es la variable estudiada y $p(x|\omega_i)$ y $p(x|\omega_j)$ son las funciones de probabilidad para un determinado x , en ω_i y ω_j respectivamente.

Valores de 0 serían dos clases que se solapan completamente y de 2 serían dos clases completamente separadas (Larrañaga & Alvarez-Mozos, 2016b), también se podría considerar que valores entre 0 y 1 corresponden a una muy pobre separabilidad, entre 1 y 1.5 corresponden a una pobre separabilidad, y entre 1,5 y 2 corresponden a una separabilidad alta (Skriver, 2007). Para el cálculo de la distancia JM, se utilizó una función en lenguaje R facilitada por el tutor del trabajo.

Realizado el análisis de separabilidad, se realizó la clasificación, mediante el algoritmo Random Forest (RF) en lenguaje R, con base a extractos de código por (Gil Martínez, 2018; Santacruz, 2015), haciendo uso de la librería *caret* (Classification and Regression Training) (Kuhn et al., 2019).

El algoritmo **Random Forest (RF)** (Breiman, 2001), consiste de una colección de clasificadores basados en árboles estructurados; es un método que combina árboles de decisión independientes probados sobre un conjunto de datos seleccionados aleatoriamente

con igual distribución, cada árbol da una clasificación y el resultado es la clase con mayor número de votos en todo el bosque (figura 16).

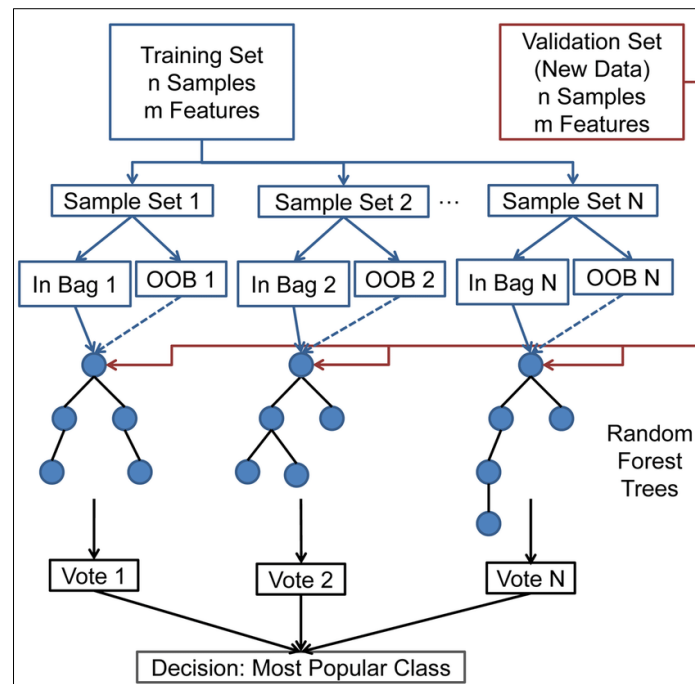


Figura 16. Estructura del algoritmo Random Forest
Fuente: (Orellana Alvear, 2018)

Cada árbol de decisión (k) se forma a partir de un conjunto de datos de entrenamiento, tomados aleatoriamente y con reemplazo, los nodos de cada árbol se construyen utilizando la mejor variable de división entre un subconjunto (m) de variables predictivas seleccionados al azar, acorde a una determinada medida que maximice un estadístico de desigualdad o desorden (coeficiente de Gini o entropía). Cuanto mayor sea la pureza del nodo, menor el valor del índice Gini; con la entropía se mide el grado de desorden, que se corresponde con la impureza, si un nodo es puro su entropía es cero, de esta forma el resultado de cada árbol es independiente (Amat Rodrigo, 2018; Larrañaga & Alvarez-Mozos, 2016a).

2.5. Evaluación de los resultados

Internamente el clasificador RF guarda para cada árbol $1/3$ del conjunto de datos de entrenamiento para calcular el *error out of bag* (OOB), el cual se estima de forma interna para optimizar los parámetros (árboles de decisión y variables predictivas); adicionalmente a ello se procedió a evaluar la fiabilidad de la clasificación utilizando el conjunto de datos externos, haciendo uso de matrices de confusión.

Con los resultados obtenidos en la clasificación y el conjunto de datos, se generó dicha matriz, la cual refleja los conflictos que se presentan entre el mapa clasificado y la realidad (Chuvienco & Huete, 2010). De esta matriz se generan una serie de cálculos estadísticos con los cuales se validó numéricamente los resultados de la clasificación. En la siguiente tabla se presenta la estructura de una matriz de confusión (Chuvienco, 2010).

Tabla 4. Estructura de una matriz de confusión (clasificación)

		Referencia					Fiabilidad usuario
		Clase 1	Clase 2	Clase 3	Clase n	Total	
Clasificación	Clase 1	X_{11}				X_{1+}	X_{11}/X_{1+}
	Clase 2		X_{22}			X_{2+}	X_{22}/X_{2+}
	Clase 3			X_{33}		X_{3+}	X_{33}/X_{3+}
	Clase n				X_{nn}	X_{n+}	X_{nn}/X_{n+}
	Total	X_{+1}	X_{+2}	X_{+3}	X_{+n}	ΣX_{ij}	
	Fiabilidad productor	X_{11}/X_{+1}	X_{22}/X_{+2}	X_{33}/X_{+3}	X_{nn}/X_{+n}		

La diagonal de la matriz corresponde a los puntos en donde se produce acuerdo entre la imagen clasificada y la realidad, mientras los marginales suponen errores de asignación. Los cálculos estadísticos derivados de esta matriz que se utilizaron para validar la clasificación fueron:

Fiabilidad global, se obtiene relacionando los elementos de la diagonal con el total de puntos muestreados (Chuvieco & Huete, 2010).

$$\hat{F} = \frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}}$$

Donde x_{ii} corresponde a los valores de la diagonal en cada columna y x_{ij} el valor en la fila i (clasificador) y el valor en la columna j (referencia), de la matriz de confusión.

La fiabilidad global, como se calcula a nivel general puede ocultar diferencias en las categorías, para ello se requiere un análisis que incluya las celdillas marginales (Chuvieco, 2010), como los que se presenta a continuación.

Fiabilidad del productor, probabilidad de que los píxeles de una determinada clase i , realmente correspondan a dicha clase en la imagen clasificada.

$$Fp_i = \frac{X_{ii}}{X_{+i}}$$

Fiabilidad del usuario, es la probabilidad de que los píxeles clasificados como la clase i representen realmente dicha clase en el terreno.

$$Fu_i = \frac{X_{ii}}{X_{i+}}$$

Estadístico Kappa, es una medida de la diferencia entre el acuerdo observado (mapa-realidad) y el que cabría esperar por el azar, se calcula (Hudson & Ramm, 1987):

$$\hat{k} = \frac{n \sum_{i=1,n} X_{ii} - \sum_{i=1,n} X_{i+} X_{+i}}{n^2 - \sum_{i=1,n} X_{i+} X_{+i}}$$

Donde n es el tamaño de la muestra, X_{ii} píxeles correctamente clasificados, y el producto de los marginales X_{i+} y X_{+i} .

Los resultados van en un rango entre 0 y 1, en la siguiente tabla se indica una clasificación de la calidad de los valores propuestas por (Landis & Koch, 1977).

Tabla 5. Clasificación del estadístico Kappa

Estadístico Kappa	Clasificación
< 0.00	Malo
0.00-0.20	Leve
0.21-0.40	Razonable
0.41-0.60	Moderado
0.61-0.80	Considerable
0.81-1.00	Casi perfecto

Con base a la clasificación obtenida y el 30% de las áreas consideradas para la validación de la misma se procedió a construir la matriz de confusión en QGIS, utilizando el complemento “Semi-Automatic Classification” desarrollado por Congedo (2018).

2.6. Detección de cambios de uso del suelo

Para cuantificar el cambio de uso del suelo, se realizó un análisis de los cultivos de arroz, caña de azúcar, banano y camarón, por ser los más importantes en la zona en cuanto a su extensión e importancia en su producción y comercio. El resto de cultivos se los agrupó en una categoría llamada “otros cultivos”. En esta categoría se encuentran: palma, cacao, vegetación arbustiva (matorral), vegetación herbácea y pastos, no se considera el manglar ni bosque ya que forman parte de la REMCh, y sus límites y su uso se encuentran definidos.

La evaluación del cambio del uso de suelo se realizó tomando en cuenta una franja de 1 km alrededor de la reserva (zona buffer) y el resto que contempla el área de estudio (figura 17). En este estudio se ha considerado esta zona buffer como área de amortiguamiento, aunque en términos legales, en 1992 se definió en 100 metros de ancho en la falda de los cerros (Yanez, 1996).




Figura 17. Delimitación zona buffer alrededor de la reserva
Fuente: Elaboración propia

Para ello se transformó a archivo vectorial el mapa clasificado con QGIS, del cual se consideraron las clases (cultivos) de interés y posteriormente se trataron individualmente para eliminar el ruido (polígonos de astilla); teniendo las áreas de los cultivos finales, estas se transformaron a raster para poder realizar la detección de cambios con el mapa del año 2015 (IEE et al., 2015).

Con los mapas de uso de suelo tipo raster del año 2015 y 2018, se realizó una resta entre ambos, quedando en evidencia las modificaciones del uso del suelo con respecto al año 2015. Este proceso se realizó en Arcgis, pero también se puede realizar en QGIS.

3. RESULTADOS Y DISCUSIÓN

3.1. Matrices de correlación

Los valores de correlación más altos se encuentran en un rango entre 0.87 y 0.90, que corresponden a sendas imágenes en las polarizaciones VHdb y VVdb, ocurriendo lo contrario al correlacionar estas con el ratio qdb, en donde los resultados indican una correlación negativa y baja, también se observa una correlación similar entre los diferentes pares de fechas en las polarizaciones VHdb y VVdb, no así en qdb, por ejemplo entre enero mayo y septiembre (tabla 6). En el anexo 1 se presenta una tabla que contiene la correlación entre todas las bandas.

Tabla 6. Correlación entre enero, mayo y septiembre

Bandas Fechas			18-may			21-sep		
			b13	b14	b15	b25	b26	b27
			VHdb	VVdb	qdb	VHdb	VVdb	qdb
12-ene	b1	VHdb	0.78	0.78	-0.35	0.72	0.69	0.01
	b2	VVdb	0.76	0.79	-0.38	0.70	0.71	-0.06
	b3	qdb	-0.04	-0.08	0.10	-0.02	-0.09	0.13

A continuación se presentan combinaciones RGB, de algunas imágenes.

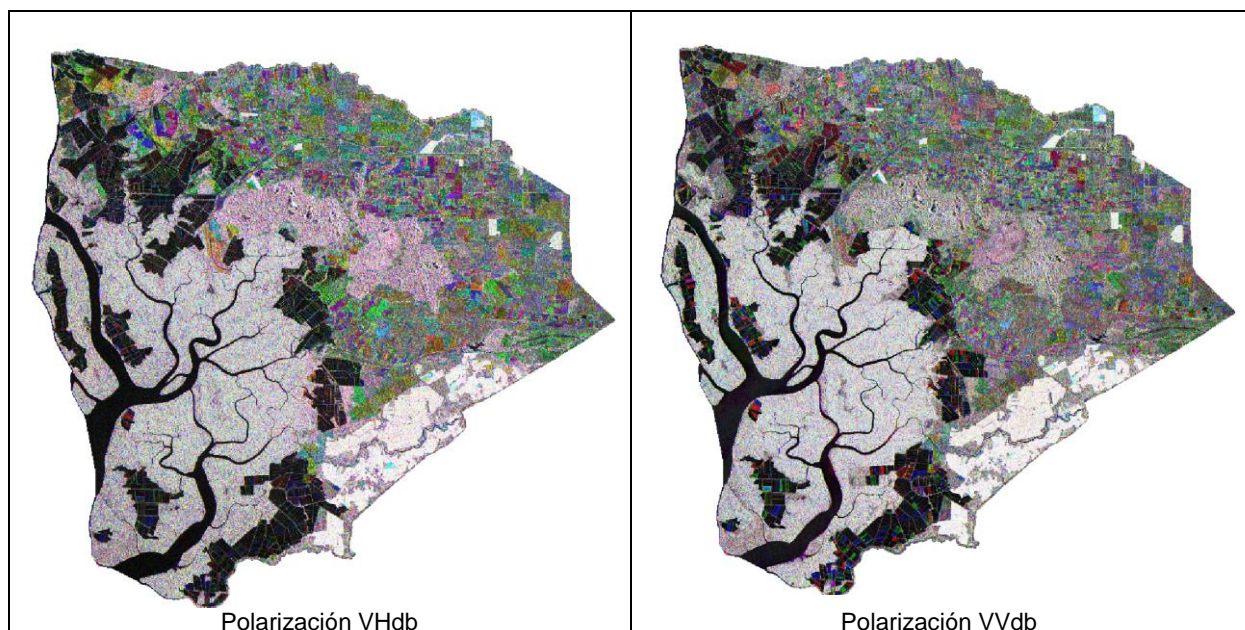


Figura 18. Combinación RGB, para el 12-ene, 18-may, 21-sep




Figura 19. Combinación RGB, para el 17-feb, 17-jun, 03-oct

En las combinaciones presentadas (figuras 18 y 19), se logra visualizar una tendencia constante en tonos grises al sur este que se identifica con el cultivo de banano, al sur oeste con algo de moteado rosa que sería el manglar y el bosque ubicado en el centro norte; esto significa que en las seis fechas no existe mayor cambio con el comportamiento de aquellas cubiertas y además considerando que son de tipo perenne. Las zonas negras que se encuentran al oeste y que su color no cambia, corresponden al río Guayas y sus afluentes. En el caso de las áreas en donde predomina el color negro seguido de colores rojos, azules y verdes, corresponden a las zonas de camaronerías; este cambio multicolor está relacionado con el proceso de vaciado de las piscinas y en donde si existen valores de retrodispersión este comportamiento se puede ver a detalle con la curva media temporal del cultivo. Para el resto de área, en donde predominan mayormente los cultivos de caña y arroz, casi no se ve un patrón definido, salvo en ciertas áreas; esto nos da una idea de que la producción de los cultivos en la zona es de manera intermitente.

En las siguientes gráficas se muestran las curvas medias temporales de los cultivos de camarón, arroz, caña de azúcar y banano, en la zona de amortiguamiento de la REMCh, tomando en cuenta una parcela por cada cultivo, este comportamiento podría ser diferente en otras parcelas. Los valores aquí representados son referenciales, nos da una idea del comportamiento de los cultivos a lo largo del año en las diferentes polarizaciones, para interpretar de una mejor manera es preciso conocer los calendarios de siembra reales y conocer un poco más del comportamiento de dichas cubiertas.

Camarón




Figura 20. Curvas temporales de retrodispersión del camarón: VHdb, VVdb y qdb

Por el tipo de retrodispersión superficial que se dan en superficies de aguas en calma en la que predominan las polarizaciones directas, los valores en VVdb son más altos que en VHdb. El valor más bajo en VVdb se da en junio lo que se ve reflejado en qdb en donde en esa fecha se ve el valor más alto, predominando el mecanismo de retrodispersión en VH.

Arroz




Figura 21. Curvas temporales de retrodispersión del arroz: VHdb, VVdb y qdb

Tomando en cuenta que el arroz es un cultivo que durante la mayor parte de su desarrollo es bajo inundación, a nivel general se puede ver que predomina la polarización en VVdb. Al analizar la curva qdb el ratio entre las dos polarizaciones, se denotan dos picos en positivo en marzo y agosto, en donde la polarización en VHdb predomina, lo que se relaciona con el punto de crecimiento máximo del cultivo. Se podría concluir de que en esa parcela se han realizado dos cosechas en ese año.

Caña de azúcar




Figura 22. Curvas temporales de retrodispersión de la caña de azúcar: VHdb, VVdb y qdb

En general la curva temporal de la caña de azúcar mantiene una tendencia constante. En febrero presenta el pico más alto, luego a partir de marzo esta se estabiliza. Predomina la polarización en VVdb.

Banano




Figura 23. Curvas temporales de retrodispersión del banano: VHdb, VVdb y qdb

Tomando en cuenta de que el banano de cierta forma es perenne, y se van realizando cosechas paulatinamente; la curva temporal tanto en VHdb y VVdb es constante, en qdb se mantienen picos positivos y negativos pero siempre dentro del rango entre -5 y -10.

3.2. Análisis de separabilidad

El análisis de separabilidad, de cierta forma ayuda a entender los resultados que se obtengan de la clasificación, la certeza de los datos de este análisis se ve influenciado por la calidad del set de entrenamiento, en las siguientes gráficas de tipo radial, se representa el análisis de separabilidad entre las distintas clases.

Cultivo de arroz

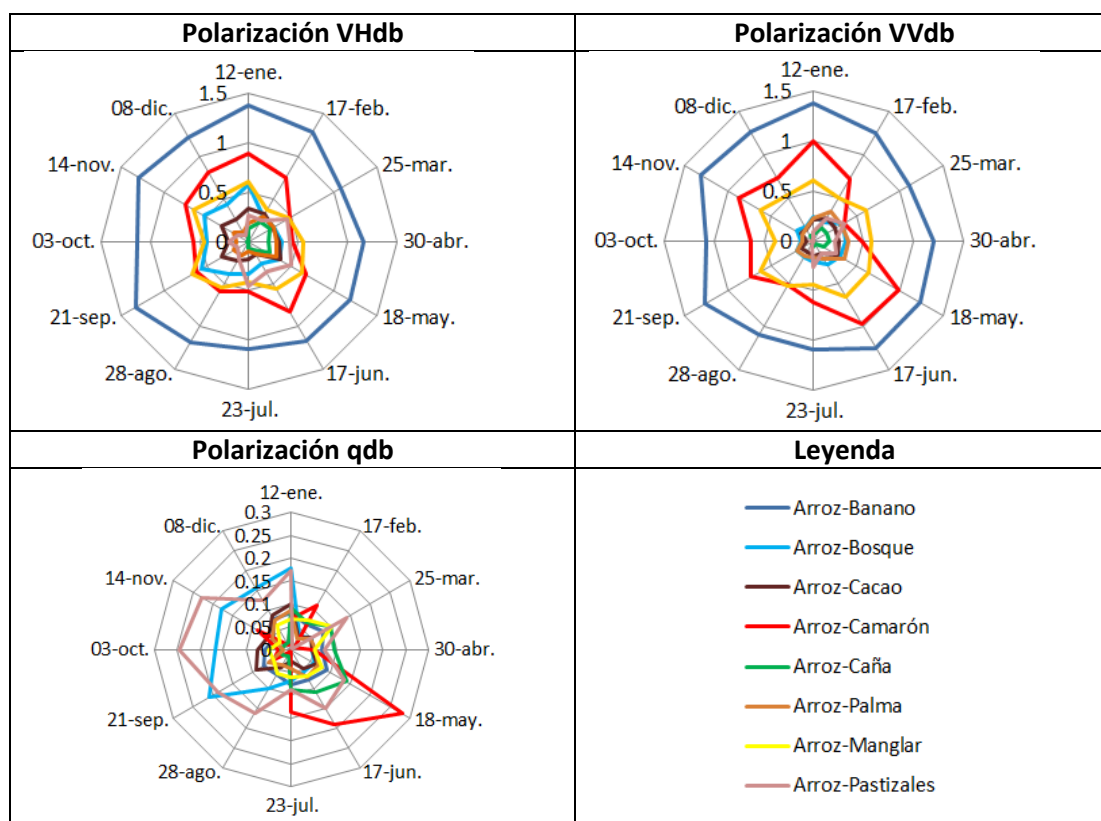


Figura 24. Análisis separabilidad arroz

En las polarizaciones VHdb y VVdb la separabilidad es similar en las diferentes combinaciones del cultivo de arroz, siendo el banano con el que mejor se separa. Con el camarón existe una baja separabilidad en la polarización VVdb el 25 de marzo y 28 de agosto, lo que podría estar relacionado con las parcelas de arroz inundadas ya sea por la preparación del terreno (fangueo), o por el desarrollo del cultivo en sus primeros días; con el cultivo que menos separabilidad presenta en ambas polarizaciones es con la caña de azúcar, la separabilidad más alta se da en la polarización VHdb el 25 de marzo luego una baja el 30 de abril, sube de nuevo el 18 de mayo para luego ir en descenso hasta llegar a valores de 0.

En qdb la separabilidad es variante a lo largo del año pero en general baja. Existen varios picos en las combinaciones con el camarón, bosque y pastizales, sin embargo son valores en torno a 0.3, lo que se considera una separabilidad muy pobre.

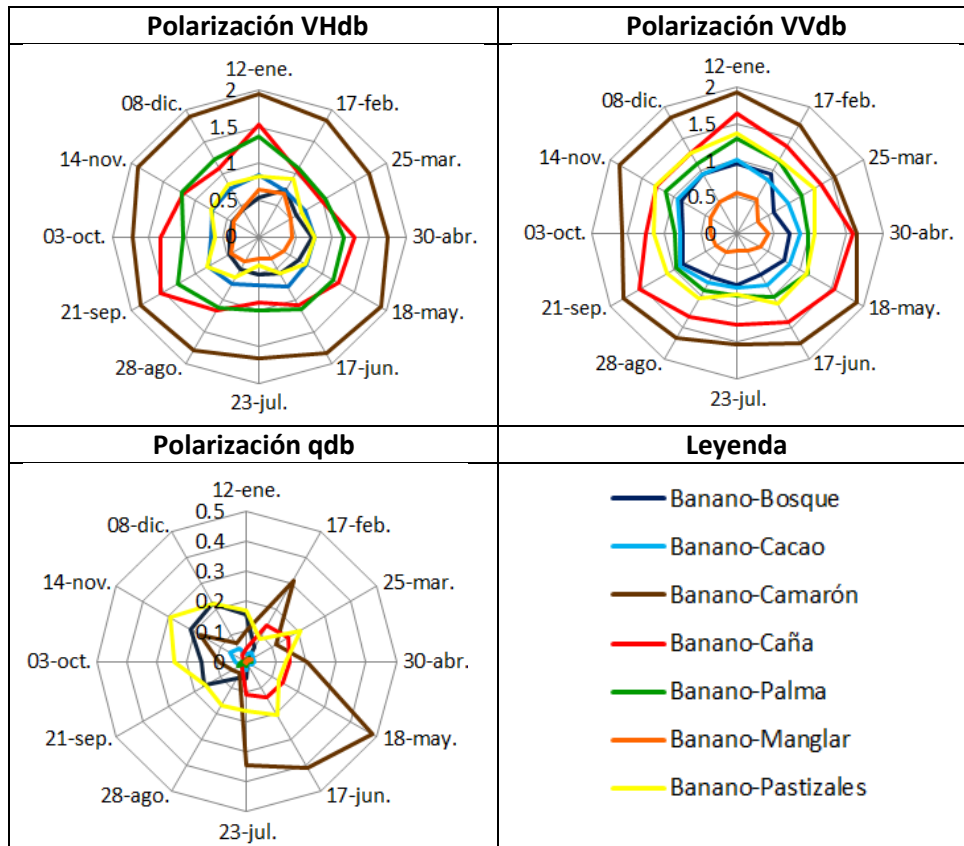
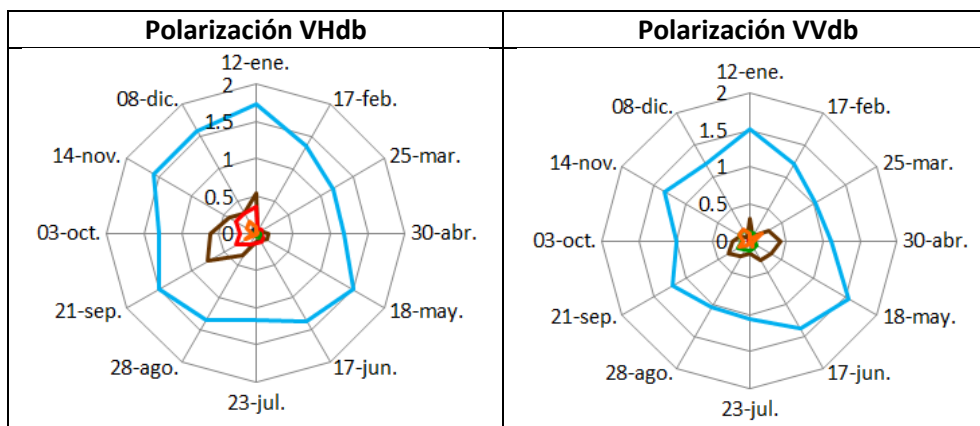


Figura 25. Análisis separabilidad banano

Se discrimina muy bien con el cultivo de camarón en VHdb, VVdb e incluso con qdb entre el 18 de mayo y 23 de julio; con la cubierta que menos se discrimina es con el manglar llegando a valores por debajo de 0.5.

Bosque






Figura 26. Análisis separabilidad bosque

En el caso del bosque, según las polarizaciones en VHdb y VVdb, con el cultivo de camarón, es con el que mayor índice de separabilidad tiene, con el resto de cubiertas se obtienen separabilidades muy bajas.

Cacao




Figura 27. Análisis separabilidad cacao

Así como en el bosque, el cacao tiene mejor índice de separabilidad con el camarón en VHdb y VVdb.

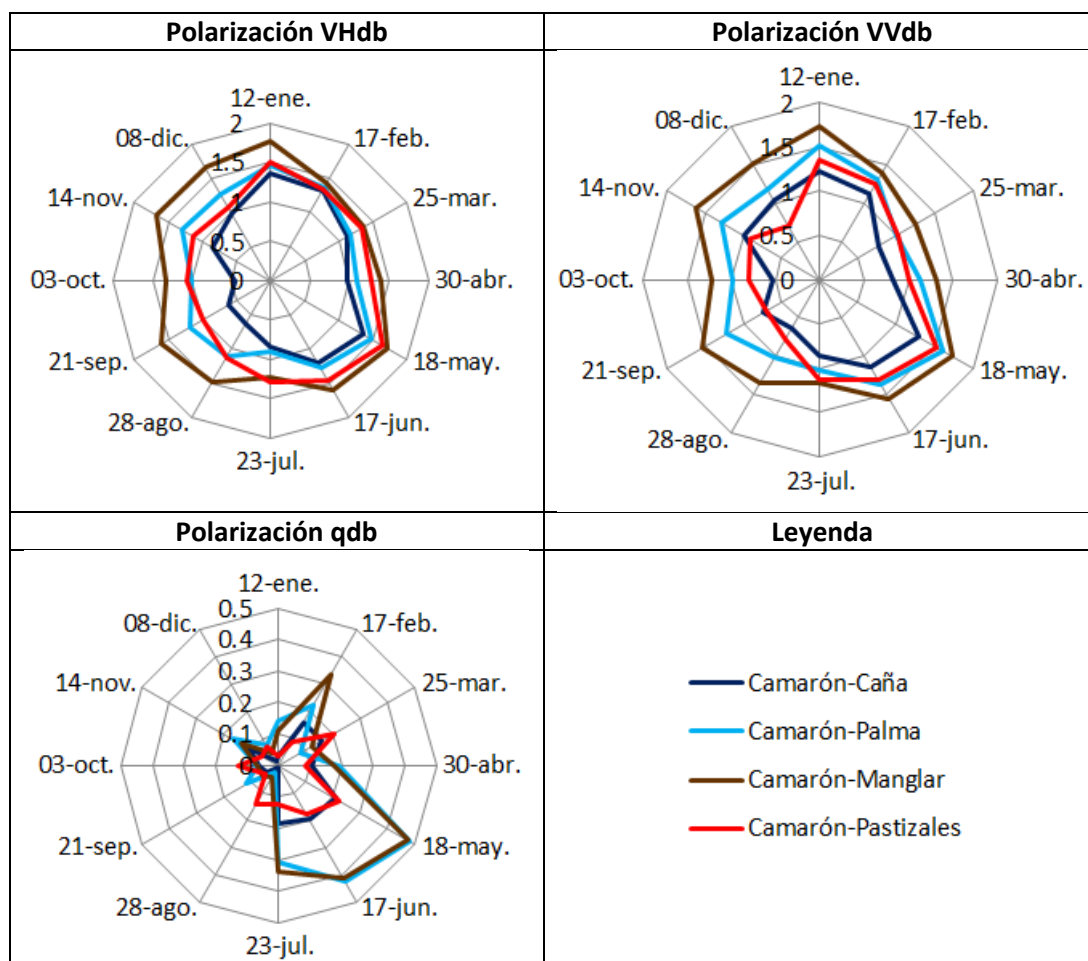
Camarón


Figura 28. Análisis separabilidad camarón

La separabilidad con las demás combinaciones de cultivos es regularmente alta en las polarizaciones VHdb y VVdb, un caso especial se da con el cultivo de arroz que se desarrolla bajo inundación y como ya se mencionó, en ciertas épocas del año el comportamiento de ambas cubiertas sería similar, sobre todo en los primeros días de desarrollo del cultivo de arroz.

Caña, Palma y Manglar

En las combinaciones entre caña, palma y manglar, en VVdb, se puede ver un mayor grado de separabilidad, en el caso de los pastizales en VHdb es un poco mayor, sin embargo sigue siendo baja.




Figura 29. Análisis separabilidad caña de azúcar, palma y manglar

3.3. Clasificación supervisada

Estudios demuestran que utilizando el algoritmo Random Forest sobre imágenes radar, es posible obtener resultados satisfactorios a la hora de determinar usos de suelo, (Caballero et al., 2018; Larrañaga & Alvarez-Mozos, 2016a).

En este estudio el resultado de la clasificación con RF fue considerable (figura 31), utilizando en total las 36 bandas en las polarizaciones VHdb, VVdb y qdb; la precisión del algoritmo fue de 0.87 y un coeficiente de Kappa de 0.84 usando un mtry de 10 (n° de variables seleccionadas aleatoriamente en cada árbol por RF), 500 árboles y cinco validaciones cruzadas. El error OOB (out of bag) fue de 12.5%, en los resultados de la matriz de confusión generados por RF, podemos saber de antemano cuales son las clases en las que el error de clasificación es alto.

En cuanto a las variables (bandas), más importantes seleccionadas por RF para la clasificación, toma en cuenta la disminución de la precisión media (*Mean Decrease Accuracy*). En el siguiente gráfico se representa la importancia de las bandas en función a este índice.




Figura 30. Ranking de importancia de valores

Lo que se puede observar en la figura 30, la banda 7, 11 y 20 tienen mayor influencia en el rendimiento de la clasificación, estas corresponden a la polarización en VHdb del 25 de marzo y VV del 30 de abril y 23 de julio.

En la evaluación del mapa clasificado con el 30 % de las áreas asignadas para la validación por medio de la matriz de confusión (tabla 7), resulta una precisión de un 84% con un coeficiente de Kappa de 0.80 que según (Landis & Koch, 1977) sería considerable.

Tanto en el mapa resultante, como en las matrices de confusión se denota que los cultivos de cacao, palma y pastizales no han sido correctamente clasificados, esto podría ser por varias razones:

- a) El número y tamaño de muestras señaladas en el set de entrenamiento no fueron suficientes: a diferencia de los demás cultivos en caso particular de estas cubiertas, el área existente con relación al área de estudio no es grande (cacao 4%, palma 1%, pastos 2%), entonces a estas clases se le asignó un número menor de muestras que las demás.
- b) El comportamiento de las cubiertas de dichos cultivos se confunde con los demás: en el caso de los pastizales aunque en la matriz de confusión no le atina ninguna, el análisis de separabilidad y la matriz de confusión del RF (anexo) nos da una idea, por ejemplo, con el cultivo de banano y palma es con el único que tiene mayor índice de separabilidad.

Tabla 7. Matriz de confusión

Clases	Arroz	Banano	Bosque	Cacao	Camaron	Caña de a.	Palma	Manglar	Pastizal	Total
Arroz	3495	0	37	48	168	282	130	91	10	4261
Banano	0	17238	48	54	0	0	0	341	0	17681
Bosque	131	16	1388	761	0	17	108	824	144	3389
Cacao	120	0	115	624	0	49	213	137	10	1268
Camaron	31	0	4	5	26317	6	2	26	10	26401
Caña de a.	2493	1	393	1345	83	8251	1390	279	101	14336
Palma	22	0	1	129	0	7	133	22	0	314
Manglar	31	525	1189	1805	2	14	195	14067	42	17870
Pastizal	0	0	0	0	0	0	0	0	0	0
Total	6323	17780	3175	4771	26570	8626	2171	15787	317	85520

El cultivo de banano, caña de azúcar, camarón, y manglar, son los que mejor se clasifican, el arroz se clasifica con menor precisión, tiende a confundirse con la caña de azúcar principalmente, tal como se ve en la matriz de confusión (tabla 7) y visto en el análisis de separabilidad, seguido del camarón. El bosque aunque visualmente se logra distinguir sus límites, hay mezcla entre las demás clases a excepción del camarón, lo que se debe a sus características en cuanto a su volumen que es parecido al manglar, además que en su interior hay diferencia entre ecosistemas como el bosque seco y bosque húmedo. En la tabla 8 se puede visualizar la fiabilidad del usuario y productor de cada una de las clases.

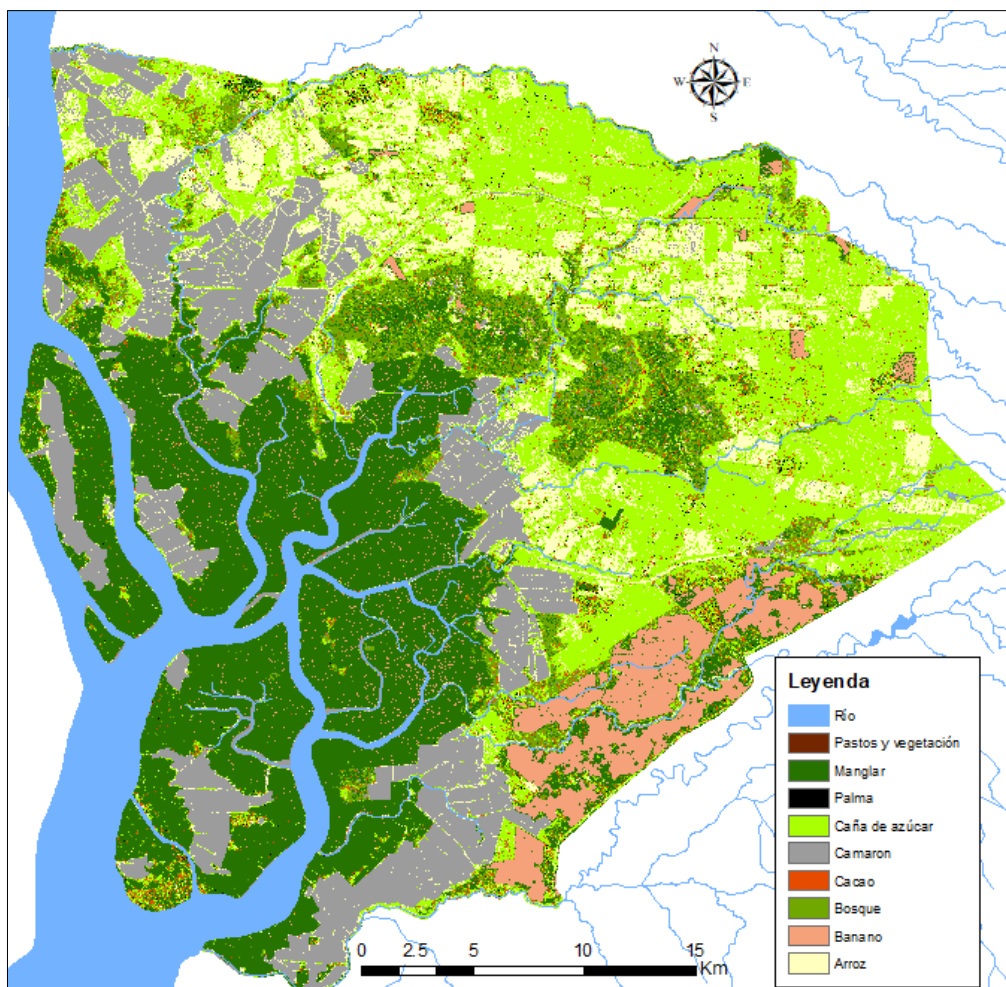


Figura 31. Resultado de la clasificación

Tabla 8. Fiabilidad del usuario y productor

Clases	Fiabilidad del productor	Fiabilidad del usuario	Coefficiente Kappa
Arroz	55.27	82.02	0.81
Banano	96.95	97.49	0.97
Bosque	43.72	40.96	0.39
Cacao	13.08	49.21	0.46
Camaron	99.05	99.68	1.00
Caña de a.	95.65	57.55	0.53
Palma	6.13	42.36	0.41
Manglar	89.10	78.72	0.74
Pastizal	0	nan	nan

Aunque los resultados obtenidos de la clasificación no son despreciables, esta se podría mejorar e ir probando, por ejemplo, seleccionar áreas más pequeñas y hacer clasificaciones por partes, tratando de que el número de muestras por clases sea lo más homogénea posible. Estudios también han demostrado que las combinaciones entre imágenes radar y ópticas mejoran la precisión de la clasificación (Mercier et al., 2019; Orynbaikyzy et al., 2019).

3.4. Detección de cambios de uso del suelo

Los usos del suelo, hasta el año 2018 (tabla 9 figura 32 y 33), han presentado cambios en sus áreas de ocupación que indican las tendencias a corto y mediano plazo.

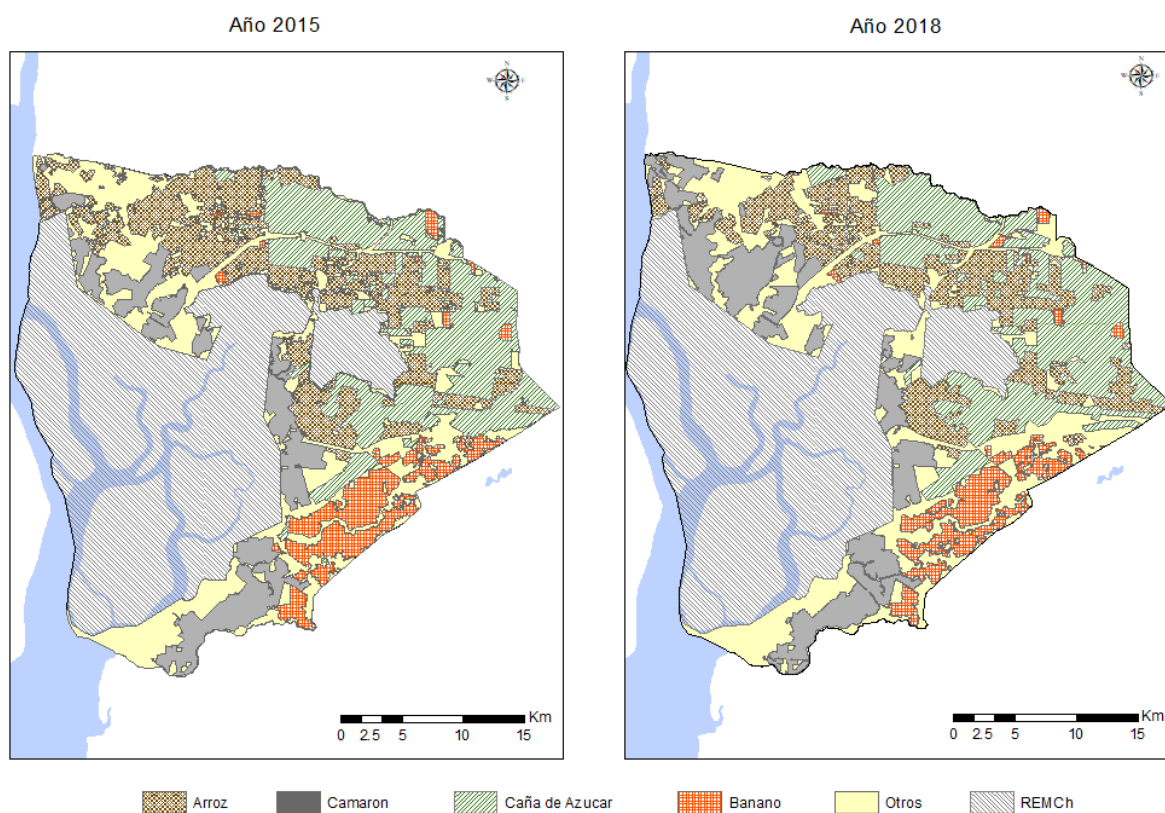


Figura 32 Usos de suelo 2015-2018

Tabla 9. Cambios de uso de suelo 2015-2018

Cultivo	Área de amortiguamiento			Alrededor > 1km		
	2015	2018	Diferencia (ha)	2015	2018	Diferencia (ha)
Camarón	2716	2988	272	7256	9714	2458
Banano	118	79	-39	6478	5626	-852
Caña de azúcar	1070	1196	126	17212	17428	216
Arroz	2592	2010	-582	15164	12556	-2608
Otros	4801	5024	-223	16283	17068	786

En el siguiente mapa, se presenta la diferencia de cambios entre el 2018 y 2015, en donde los tonos grises corresponden a zonas en donde el uso del suelo ha sufrido modificaciones.

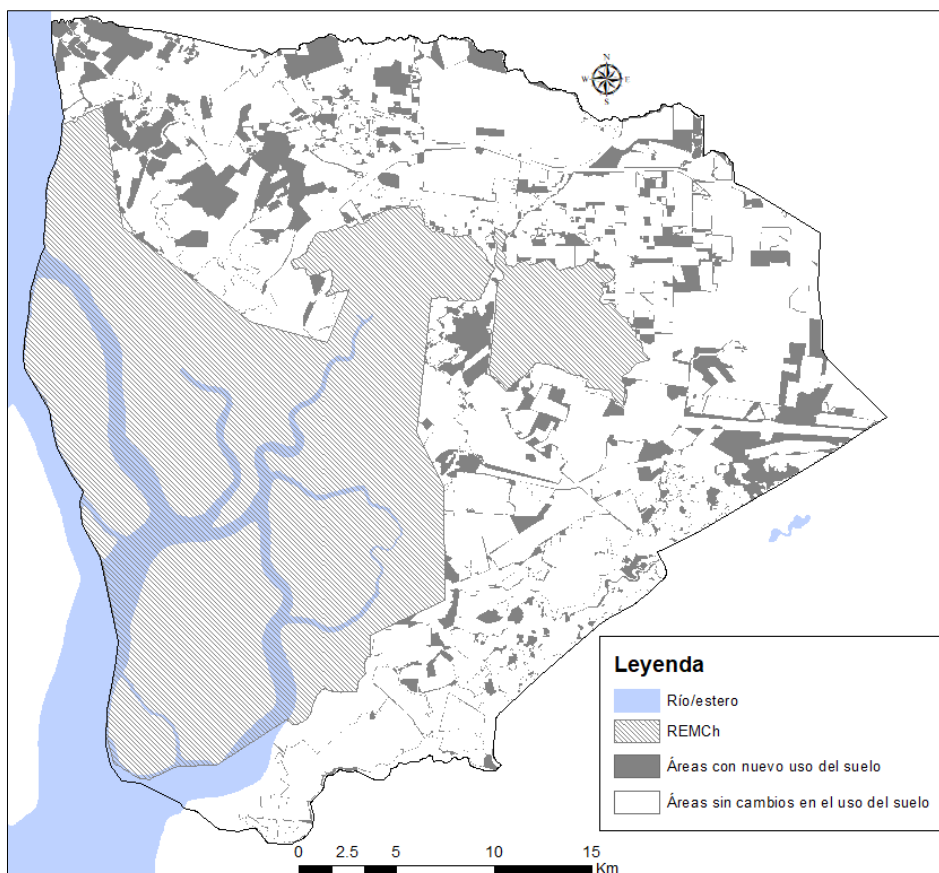


Figura. 33 Cambios de uso de suelo 2018

En el año 2013, el precio del camarón ecuatoriano se incrementó debido a que en los países de Centroamérica y Asia se presentó en sus granjas camaroneras la enfermedad Necrosis Aguda del Hepatopáncreas (Palacios, 2016), lo que produjo un incremento del área cultivada y un aumento de la producción. Para el 2018 este cultivo ha ocupado los terrenos localizados en las márgenes de esteros con influencia de la marea, donde existía pasto natural y algunas parcelas de arroz.

A nivel nacional, la producción del arroz en el 2017 disminuyó un 16% respecto al 2016, a lo que se le atribuye una reducción en su superficie de un 20% (MAG & SIPA, 2017a), para el 2018 en el área de este estudio se denota esa reducción, como ya se mencionó, cultivos de arroz han sido reemplazados por cultivos de camarón y también por caña de azúcar (figura 32). La superficie nacional cosechada de caña de azúcar se incrementó en el 2017 (MAG & SIPA, 2017b) aunque en ese año la producción disminuyó en un 2%, debido a las condiciones climáticas. Entre los derivados de la caña de azúcar que se exportan están: confitería, alcohol etílico sin desnaturalizar, alcohol etílico y aguardiente desnaturalizado,

azúcar de caña, azúcar los demás y azúcar orgánica certificada. En el 2018, pequeñas áreas de banano fueron reemplazadas por arroz y caña de azúcar, en otras el banano gana terreno a la caña de azúcar; en el área de amortiguación se da una reducción de 39 hectáreas aproximadamente (figura 32).

En general, la tendencia de uso del suelo alrededor de la REMCh es la de incrementar el área ocupada para el cultivo de camarón blanco y caña de azúcar. Las granjas acuícolas han ocupado los suelos arcillosos en los que eran ocupados para el cultivo de arroz, sobre todo los que tienen acceso a cursos de agua con influencia de las mareas del estuario del río Guayas. Estos cambios en el uso del suelo incrementan los riesgos de impactos sobre los recursos naturales que protege la REMCh. La reducción de riesgos de inundaciones por la construcción de un sistema de canales de alivio en 1997 produjo, en 21 años, un cambio de uso del suelo de áreas con pastos y cultivos estacionales, a otros de alta intensidad de uso de los recursos y mayor productividad financiera.

En Ecuador, las áreas alrededor de los límites de las áreas naturales protegidas no tienen un régimen de manejo especial, pero son parte de los objetivos de manejo de la unidad protegida. Sin embargo, las áreas naturales protegidas cuentan solo con recursos financieros y humanos limitados, por lo que no es factible un control permanente sobre estas áreas y se prevé un deterioro de la calidad ambiental en las áreas de la REMCh más cercanas al perímetro.

El Estado ecuatoriano podría iniciar un proceso de estímulos de certificación de las actividades con mayor probabilidad de producir impactos ambientales, como son la acuicultura del camarón y el cultivo de arroz en la franja de un kilómetro alrededor de la REMCh. La certificación del camarón abre mercados más exigentes que generarían mayores beneficios económicos a los propietarios de las granjas camaroneras a cambio de mejorar sus prácticas de producción. De tal forma que el mismo productor reduciría, a su beneficio, los riesgos de contaminación del agua, conflictos con los pescadores artesanales y control de depredadores naturales con métodos no letales.

Para los cultivos de arroz y banano se requeriría un proceso de transferencia de tecnología basado en la sostenibilidad y la responsabilidad social arroceras que estimule la organización, la competitividad y la rentabilidad del productor, implementando tecnologías en forma integral para aumentar los rendimientos, reducir los costos por tonelada en el cultivo del arroz y disminuir los impactos sobre los recursos naturales de la Reserva Ecológica Manglares Churute.

4. CONCLUSIONES

El seguimiento de cambios en el uso del suelo, así como de la estacionalidad y ciclos de los cultivos y de la vegetación, alrededor (o al interior) de áreas naturales protegidas, se puede automatizar mediante el uso de los SIG y la Teledetección, utilizando herramientas de libre acceso, tales como: SNAP, QGIS, lenguaje R e imágenes de satélite de acceso libre como lo es la familia Sentinel. En este estudio con el uso de las imágenes radar, se ha demostrado que es posible determinar los cambios en el uso del suelo, utilizando una metodología sencilla a bajo costo, que va desde la obtención de las imágenes, procesamiento de las mismas, clasificación de cultivos, análisis multitemporal de los cultivos y detección de cambios en diferentes fechas; sin embargo este análisis requiere de trabajo de campo para validar la información generada.

El éxito de la clasificación supervisada de los cultivos, mediante el uso de sistemas inteligentes para la extracción de información de las imágenes de satélite, como el algoritmo Random Forest, depende mucho de la calidad de información real de campo, para el entrenamiento del algoritmo, estas deben ser de forma equilibrada para las distintas categorías, sin embargo la distribución en la homogeneidad de las muestras dependerá del área de cada una de las clases.

En este estudio, el número de muestras para el entrenamiento no se presenta de forma equilibrada, lo que se debe a la magnitud de las áreas para las distintas categorías. Debido a esto el error de la clasificación de algunas clases es alto, tal es el caso del cacao, palma, bosque, pastizales y vegetación en donde la clasificación es mala, ocurriendo lo contrario con el arroz, banano, caña de azúcar y camarón en donde el error de clasificación es menor. En general la precisión de la clasificación en el área de estudio es buena, gira en torno al 84% y un coeficiente Kappa de 0.80. Es posible equilibrar estos problemas de clasificación no balanceado, mediante técnicas de muestreo como *under-sampling*, *over-sampling*, limpieza de datos o híbridas, con las cuales es posible incrementar la precisión de la clasificación.

Con este estudio se determinó que entre los años 2015 y 2018 se han producido importantes cambios en el uso del suelo que podrían influir de forma negativa en la conservación de los recursos naturales del área natural protegida analizada. Un incremento en el área dedicada a la acuicultura del camarón blanco y de los cultivos agrícolas de caña de azúcar y banano deberían ser asuntos para analizar durante la elaboración del siguiente Plan Operativo de la Reserva Ecológica Manglares Churute. Aunque estos cambios se han producido en las áreas que rodean al área natural protegida no dejan de influir sobre la conservación de los recursos naturales. Varias prácticas que se realizan en estos usos del suelo, como el uso de fertilizantes y pesticidas, deterioro de la calidad del agua y conflictos con las comunidades locales, podrían ser mejoradas mediante el estímulo a la certificación de sus prácticas y al mismo tiempo mejorar el acceso a otros mercados.

5. BIBLIOGRAFÍA

- Amat Rodrigo, J. (2018). Árboles de predicción: bagging, random forest, boosting y C5.0. Retrieved May 19, 2019, from https://rpubs.com/Joaquin_AR/255596
- Breiman, L. (2001). RANDOM FORESTS. *Leo. Machine Learning*, 45(1), 5–32. <https://doi.org/https://doi.org/10.1023/A:1010933404324>
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to Remote Sensing* (5th ed.). Guilford Press.
- Chuvieco, E. (2010). *Teledetección Ambiental* (1st ed.). Barcelona, España: Editorial Planeta, S. A.
- Chuvieco, E., & Huete, A. (2010). *Fundamentals of satellite remote sensing*. CRC Press.
- Congedo, L. (2018). Semi-Automatic Classification Plugin. Retrieved from <https://plugins.qgis.org/plugins/SemiAutomaticClassificationPlugin/>
- Dabboor, M., Howell, S., Shokr, M., & Yackel, J. (2014). The Jeffries–Matusita distance for the case of complex Wishart distribution as a separability criterion for fully polarimetric SAR data. *International Journal of Remote Sensing*, 35(19), 6859–6873. <https://doi.org/10.1080/01431161.2014.960614>
- Del'Arco Sanches, I., Feitosa, R. Q., Achancaray Diaz, P. M., Dias Soares, M., Barreto Luiz, A. J., Schultz, B., & Pinheiro Maurano, L. E. (2018). Campo Verde Database: Seeking to Improve Agricultural Remote Sensing of Tropical Areas. *IEEE Geoscience and Remote Sensing Letters*, 15(3), 369–373. <https://doi.org/10.1109/LGRS.2017.2789120>
- ECOLAP, & MAE. (2007). Guía del Patrimonio de Áreas Naturales Protegidas del Ecuador. Quito-Ecuador. Retrieved from <https://www.parks-and-tribes.com/national-parks/reserva-ecologica-churute/reserva-ecologica-manglares-churute.pdf>
- Elbers, J. (2011). Las áreas protegidas de América Latina: Situación actual y perspectivas para el futuro (p. 277). Quito-Ecuador: UICN-Unión Internacional para la Conservación de la Naturaleza y de los Recursos Naturales.
- ESA. (2019). SENTINEL-1. Retrieved June 20, 2019, from <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- Florio de Real, S., Real, F., & Florio, G. (2012). FENOLOGÍA DEL BANANO Ó CAMBUR (Musa AAA) EN VENEZUELA. Retrieved June 19, 2019, from <http://www.sunshineflorio.blogspot.com/2012/07/fenologiadel-banano-o-cambur-musa-aaa.html>
- Gil Martínez, C. (2018). ÁRBOLES DE DECISIÓN Y MÉTODOS DE ENSEMBLE. Retrieved May 24, 2019, from https://rpubs.com/Cristina_Gil/arboles_ensemble
- Hockings, M. (2003). Systems for Assessing the Effectiveness of Management in Protected Areas. *BioScience*, 53(9), 823–832.
- Hudson, W. D., & Ramm, C. W. (1987). Correct formulation of the Kappa coefficient of agreement. *Photogrammetric Engineering & Remote Sensing*, 53(4), 421–422.

- IEE, MAGAP, & CGSIN. (2015). GENERACIÓN DE GEOINFORMACIÓN PARA LA GESTIÓN DEL TERRITORIO A NIVEL NACIONAL ESCALA 1: 25000; SISTEMAS PRODUCTIVOS.
- Ingenio San Carlos. (2013). Proceso de producción de azúcar. *Ing. San Carlos, TOMO 1*, 1–7.
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., ... Hunt, T. (2019). Package 'caret.' Retrieved from <https://cran.r-project.org/web/packages/caret/caret.pdf>
- Landis, J. . R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159–174. <https://doi.org/10.2307/2529310>
- Larrañaga, A., & Alvarez-Mozos, J. (2016a). *Clasificación de cultivos a partir de observaciones de teledetección radar. Aplicación a zonas de secano y regadío de Navarra*. Universidad Pública de Navarra.
- Larrañaga, A., & Alvarez-Mozos, J. (2016b). On the Added Value of Quad-Pol Data in a Multi-Temporal Crop Classification Framework Based on RADARSAT-2 Imagery, (June). <https://doi.org/10.3390/rs8040335>
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *Remote sensing and image interpretation* (7th ed.). Jhon Wiley & Son.
- MAE. (2013). Sistema de Clasificación de Ecosistemas del Ecuador Continental. Quito: Ministerio del Ambiente del Ecuador.
- MAG, & SIPA. (2017a). Boletín Situacional - Arroz. Retrieved June 11, 2019, from http://sipa.agricultura.gob.ec/boletines/situacionales/boletin_situacional_arroz_2017.pdf
- MAG, & SIPA. (2017b). Boletín Situacional - Caña de Azúcar. Ministerio de Agricultura y Ganadería-Sistema de Información Pública Agropecuaria. Retrieved from http://sipa.agricultura.gob.ec/boletines/situacionales/boletin_situacional_cania_azucar_2017.pdf
- Mercier, A., Betbeder, J., Rumiano, F., Baudry, J., Gond, V., Blanc, L., ... Hubert-Moy, L. (2019). Evaluation of Sentinel-1 and 2 Time Series for Land Cover Classification of Forest–Agriculture Mosaics in Temperate and Tropical Landscapes. *Remote Sensing*, 11(8), 979. <https://doi.org/10.3390/rs11080979>
- Navarrete, R. (2000). Atractivos turísticos naturales de la Reserva Ecológica Manglares Churute (pp. 15–54). Guayaquil: CEDEGE, Ministerio del Ambiente, Fundación Natura.
- Olaya, V. (2014). *Sistemas de Información Geográfica*.
- Orellana Alvear, J. (2018). Árboles de decisión y Random Forest. Retrieved May 18, 2019, from <https://bookdown.org/content/2031/>
- Orynbaikyzy, A., Gessner, U., & Conrad, C. (2019). Crop type classification using a combination of optical and radar remote sensing data: a review. *International Journal of Remote Sensing*, 40(17), 6553–6595. <https://doi.org/10.1080/01431161.2019.1569791>
- Ottinger, M., Clauss, K., & Kuenzer, C. (2017). Large-scale assessment of coastal aquaculture ponds with Sentinel-1 time series data. *Remote Sensing*, 9(5). <https://doi.org/10.3390/rs9050440>

- Palacios, N. (2016). *Estudio de factibilidad para producir camarón de la especie Litopenaeus vannamei bajo un sistema de producción semi-intensivo en Ecuador*. Escuela Agrícola Panamericana, Zamorano Honduras. Retrieved from <https://bdigital.zamorano.edu/bitstream/11036/5812/1/AGN-2016-T035.pdf>
- Santacruz, A. (2015). Clasificación de imágenes con RandomForests en R (y QGIS). Retrieved May 10, 2019, from <http://amsantac.co/blog/es/2015/11/28/classification-r-es.html>
- Skriver, H. (2007). Signatures of Polarimetric Parameters and their Implications on Land Cover Classification, 4195–4198. Retrieved from <https://ieeexplore.ieee.org/document/4423775>
- Small, D. (2011). Flattening Gamma : Radiometric Terrain Correction for SAR Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 49(8), 3081–3093.
- Small, D., & Schubert, A. (2008). Guide to ASAR Geocoding. *Remote Sensing Laboratories, University of Zurich*, (1), 36.
- Swain, P. ., & King, R. . (1973). Two Effective Feature Selection Criteria for Multispectral Remote Sensing. Retrieved from <https://docs.lib.purdue.edu/larstech/39/>
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... Rostan, F. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/J.RSE.2011.05.028>
- Woodhouse, I. H. (2006). *Introduction to Microwave Remote Sensing*. Taylor & Francis.
- Yanez, B. (1996). Plan de Manejo de la Reserva Ecológica Manglares Churute-Fase 1-Tomo IV-Propuesta de Manejo INEFAN/Fundacion Natura. Retrieved May 10, 2019, from <http://simce.ambiente.gob.ec/sites/default/files/documentos/anny/El Plan de Manejo de la Reserva Ecológica Manglares Churute.pdf>

ANEXOS

Correlación de imágenes Sentinel 1, polarización VHdb, VVdb y VHdb-VVdb (qdb), 2018

Bandas Fechas	12-ene			17-feb			25-mar			30-abr			18-may			17-jun			23-jul			28-ago			21-sep			03-oct			14-nov			08-dic													
	b1 VH	b2 VV	b3 q	b4 VH	b5 VV	b6 q	b7 VH	b8 VV	b9 q	b10 VH	b11 VV	b12 q	b13 VH	b14 VV	b15 q	b16 VH	b17 VV	b18 q	b19 VH	b20 VV	b21 q	b22 VH	b23 VV	b24 q	b25 VH	b26 VV	b27 q	b28 VH	b29 VV	b30 q	b31 VH	b32 VV	b33 q	b34 VH	b35 VV	b36 q											
12-ene VH		0.88	0.17	0.68	0.68	-0.26	0.65	0.65	-0.11	0.68	0.68	-0.21	0.78	0.78	-0.35	0.72	0.73	-0.34	0.65	0.65	-0.27	0.66	0.63	0.04	0.72	0.69	0.01	0.68	0.66	-0.04	0.78	0.76	-0.09	0.78	0.76	0.00											
12-ene VV			-0.32	0.66	0.68	-0.31	0.64	0.66	-0.15	0.66	0.68	-0.23	0.76	0.79	-0.38	0.71	0.73	-0.37	0.62	0.64	-0.30	0.64	0.63	-0.01	0.70	0.71	-0.06	0.66	0.67	-0.09	0.76	0.78	-0.16	0.76	0.77	-0.07											
12-ene q				0.00	-0.05	0.11	-0.03	-0.07	0.09	-0.02	-0.05	0.07	-0.04	-0.08	0.10	-0.02	-0.06	0.10	0.01	-0.03	0.08	-0.01	-0.06	0.10	-0.02	-0.09	0.13	-0.01	-0.06	0.10	-0.02	-0.09	0.14	-0.01	-0.08	0.14											
17-feb VH					0.90	-0.16	0.65	0.61	-0.03	0.74	0.73	-0.19	0.68	0.68	-0.30	0.66	0.67	-0.32	0.71	0.72	-0.31	0.61	0.57	0.06	0.63	0.60	0.03	0.71	0.70	-0.04	0.64	0.63	-0.08	0.64	0.62	-0.01											
17-feb VV						-0.58	0.64	0.62	-0.07	0.75	0.75	-0.23	0.69	0.71	-0.33	0.67	0.69	-0.35	0.71	0.74	-0.35	0.61	0.58	0.03	0.64	0.62	0.00	0.72	0.72	-0.07	0.65	0.65	-0.11	0.64	0.64	-0.03											
17-feb q							-0.24	-0.27	0.10	-0.31	-0.34	0.16	-0.29	-0.32	0.18	-0.27	-0.31	0.21	-0.28	-0.33	0.22	-0.24	-0.26	0.04	-0.26	-0.28	0.05	-0.30	-0.33	0.09	-0.28	-0.30	0.09	-0.27	-0.28	0.05											
25-mar VH								0.88	0.08	0.64	0.62	-0.13	0.67	0.67	-0.29	0.73	0.74	-0.37	0.59	0.60	-0.28	0.69	0.66	0.03	0.69	0.66	0.01	0.59	0.58	-0.03	0.63	0.62	-0.09	0.63	0.62	-0.02											
25-mar VV									-0.41	0.62	0.62	-0.18	0.65	0.67	-0.32	0.72	0.74	-0.39	0.58	0.60	-0.29	0.68	0.68	-0.03	0.68	0.68	-0.05	0.59	0.59	-0.07	0.63	0.64	-0.13	0.63	0.64	-0.05											
25-mar q										-0.07	-0.11	0.12	-0.08	-0.11	0.11	-0.10	-0.13	0.10	-0.07	-0.10	0.08	-0.10	-0.16	0.11	-0.10	-0.16	0.12	-0.08	-0.12	0.08	-0.11	-0.15	0.10	-0.11	-0.15	0.08											
30-abr VH											0.89	-0.05	0.71	0.70	-0.28	0.69	0.69	-0.32	0.69	0.70	-0.33	0.60	0.58	0.02	0.63	0.61	0.00	0.67	0.66	-0.04	0.66	0.65	-0.07	0.66	0.64	0.01											
30-abr VV												-0.50	0.69	0.71	-0.33	0.68	0.70	-0.35	0.69	0.71	-0.34	0.60	0.59	0.00	0.63	0.63	-0.03	0.66	0.66	-0.08	0.66	0.66	-0.10	0.66	0.65	-0.02											
30-abr q													-0.17	-0.23	0.20	-0.18	-0.21	0.15	-0.20	-0.22	0.12	-0.17	-0.18	0.04	-0.18	-0.21	0.07	-0.19	-0.22	0.08	-0.19	-0.22	0.09	-0.19	-0.22	0.06											
18-may VH														0.89	-0.19	0.73	0.73	-0.33	0.63	0.65	-0.30	0.63	0.62	0.01	0.70	0.69	-0.02	0.65	0.65	-0.06	0.76	0.75	-0.09	0.76	0.74	-0.01											
18-may VV															-0.62	0.74	0.76	-0.39	0.64	0.66	-0.32	0.65	0.64	-0.01	0.72	0.72	-0.05	0.66	0.67	-0.09	0.76	0.78	-0.14	0.77	0.77	-0.05											
18-may q																-0.32	-0.38	0.27	-0.29	-0.31	0.17	-0.31	-0.32	0.04	-0.34	-0.37	0.08	-0.30	-0.33	0.09	-0.33	-0.38	0.15	-0.33	-0.37	0.10											
17-jun VH																	0.90	-0.23	0.65	0.65	-0.28	0.67	0.65	0.03	0.71	0.70	-0.02	0.63	0.63	-0.05	0.70	0.70	-0.11	0.71	0.69	-0.02											
17-jun VV																		-0.64	0.65	0.67	-0.32	0.68	0.67	0.00	0.72	0.72	-0.04	0.65	0.65	-0.07	0.71	0.72	-0.14	0.71	0.72	-0.05											
17-jun q																			-0.30	-0.34	0.22	-0.33	-0.35	0.04	-0.36	-0.38	0.06	-0.32	-0.33	0.06	-0.34	-0.37	0.12	-0.34	-0.37	0.08											
23-jul VH																					0.89	-0.18	0.61	0.57	0.06	0.62	0.58	0.04	0.68	0.66	-0.03	0.62	0.61	-0.08	0.63	0.60	0.01										
23-jul VV																						0.89	-0.18	0.61	0.57	0.06	0.62	0.58	0.04	0.68	0.66	-0.03	0.62	0.61	-0.08	0.63	0.60	0.01									
23-jul q																							-0.61	0.60	0.58	0.02	0.62	0.61	0.00	0.69	0.69	-0.06	0.63	0.64	-0.10	0.63	0.63	-0.02									
28-ago VH																								-0.25	-0.27	0.06	-0.27	-0.29	0.07	-0.30	-0.33	0.09	-0.28	-0.31	0.09	-0.28	-0.30	0.05									
28-ago VV																										0.87	0.23	0.73	0.68	0.05	0.63	0.60	-0.01	0.64	0.63	-0.08	0.65	0.63	-0.01								
28-ago q																											-0.28	0.69	0.70	-0.06	0.59	0.59	-0.06	0.62	0.63	-0.12	0.63	0.64	-0.05								
21-sep VH																												0.07	-0.05	0.18	0.02	0.06	0.00	0.12	0.03	-0.02	0.09	0.02	-0.03								
21-sep VV																														0.87	0.20	0.68	0.64	0.00	0.73	0.70	-0.06	0.73	0.70	0.00							
21-sep q																															-0.31	0.64	0.65	-0.09	0.70	0.71	-0.14	0.70	0.71	-0.06							
03-oct VH																																0.05	-0.05	0.18	0.01	-0.06	0.15	0.00	-0.06	0.13							
03-oct VV																																		0.88	0.16	0.69	0.66	-0.04	0.68	0.64	0.03						
03-oct q																																					-0.34	0.67	0.67	-0.11	0.66	0.65	-0.02				
14-nov VH																																							-0.02	-0.09	0.15	-0.03	-0.08	0.10			
14-nov VV																																										0.87	0.10	0.83	0.78	0.05	
14-nov q																																											-0.39	0.79	0.81	-0.07	
08-dic VH																																												0.87	0.20		
08-dic VV																																														0.87	0.20
08-dic q																																															-0.31
Mean	-15.62	-9.15	-6.47	-14.65	-8.43	-6.22	-14.92	-8.51	-6.41	-15.38	-9.30	-6.08	-14.58	-8.89	-5.69	-15.37	-9.25	-6.12	-15.69	-9.32	-6.37	-15.76	-8.82	-6.94	-15.85	-8.86	-6.99	-15.86	-9.15	-6.71	-15.35	-9.13	-6.22	-15.32	-9.22	-6.10											
SD	4.20	4.37	2.13	4.32	5.25	2.35	4.14	4.51	2.18	4.15	4.78	2.19	3.96	4.95	2.32	4.14	5.24	2.39	4.20	5.19	2.39	4.17	4.22	2.13	4.18	4.31	2.16	4.20	4.41	2.15	4.02	4.35	2.13	4.02													

CÓDIGO R

Random Forest

```
rm(list=ls())

#Librerias
library (caret)
library(randomForest)
library(sp)
library(raster)
library(rgdal)
library(lattice)
library(ggplot2)
library(mapproj)
library(rgeos)

#Importar imagen: conjunto VHdb, VVdb, VHdb-VVdb denominado "Stackall"
imgs<- brick("C:/TESIS/Imagenes Sentinel 1_2018/Stack/Stackall.tif")

#Asignarle un nombre específico a cada banda
names(imgs) <- paste0("B",c(1:36))

#Cargar archivo máscara del area de analisis. Del área de estudio se ha
considerado un buffer de 100 metros por el efecto borde
maskimgs<-readOGR("C:/TESIS/Clasificacion/shapes/Mask_AE_buff_100.shp")

#Explorar proyecciones
proj4string(imgs)
proj4string(maskimgs)

#Recorte para considerar el área de análisis
imgs <- crop(imgs, maskimgs)

#Hacer máscara para el área de análisis
imgs <- mask(imgs, maskimgs)

#Gráfico
spplot(imgs, main= "Imagenes Sentinel 1, polarización VHdb, VVdb y VHdb-VVdb,
2018")

#Composición en color (ejemplo)
#Mes de Enero VH,VV,VH
plotRGB(imgs, r=1, g=2, b=1, stretch="hist",scale=2000)

#Correlación de Pearson
correlation<-layerStats(imgs, 'pearson',na.rm=TRUE)
write.csv(correlation,"C:/TESIS/Estadisticas_imagenes/Correlacion/estadisticas
.csv")
win.graph()
pairs(imgs,main="Correlación entre bandas VH, VV y VHdb-VVdb, 2018")

#Desviación estándar, mínimo y máximo.
cellStats(imgs,sd,na.rm=TRUE)
cellStats(imgs,min,na.rm=TRUE)
cellStats(imgs,max,na.rm=TRUE)

#Importar áreas de entrenamiento ('train.shp')
#Función shapefile del paquete 'raster' para importar este archivo en R como
un objeto #de clase SpatialPolygonsDataFrame y crear una variable para
almacenar el nombre de la #columna 'class' que es la columna del shape que
contiene las clases.
trainData <- shapefile("C:/TESIS/Clasificacion/shapes/train.shp")
class(trainData)#"SpatialPolygonsDataFrame"
responseCol<-"class"

#Cruce de bandas con las áreas de entrenamiento, para análisis de
separabilidad y #calibración del modelo
#Los datos se almacenan en una data frame (llamado aquí dfAll)
dfAll = data.frame(matrix(vector(), nrow = 0, ncol = length(names(imgs)) + 1))
for (i in 1:length(unique(trainData[[responseCol]]))) {
  category <- unique(trainData[[responseCol]][i])
  categorymap <- trainData[trainData[[responseCol]] == category,]
  dataSet <- extract(imgs, categorymap)
  dataSet <- dataSet[!unlist(lapply(dataSet, is.null))]
  dataSet <- lapply(dataSet, function(x){cbind(x, class =
```

```
as.numeric(rep(category, nrow(x))))))}
df <- do.call("rbind", dataSet)
dfAll <- rbind(dfAll, df)}

#Guardar el archivo en formato txt, para realizar el análisis de separabilidad
con la #función 'sepMatrix.R'
write.table(dfAll, file = "C:/TESIS/Clasificacion/table.txt", row.names =
  FALSE)

#Análisis de separabilidad
separabilidad<-read.table("table.txt", head=T)

#Cargar función
source('sepMatrix.R')
jm<-sepMatrix(separabilidad)

#Entrenamiento del algoritmo RF
#Selección de muestras aleatorias
nsamples <- 25000 #"data.frame"
sdfAll <- dfAll[sample(1:nrow(dfAll), nsamples), ]
sdfAll

#Optimización de hiperparámetros
#Metodo de validación
cv <- trainControl(method="cv", number=5, search="grid")

# Hiperparámetro a evaluar: número de predictores aleatorios en cada
ramificación.
mtry <- expand.grid(.mtry=c(2:35))
set.seed(5)

# Evaluación del mejor mtry
mtry_eval <-
  train(as.factor(class)~B1+B2+B3+B4+B5+B6+B7+B8+B9+B10+B11+B12+B13+B14+B15
    +B16+B17+B18+B19+B20+B21+B22+B23+B24+B25+B26+B27+B28+B29+B30+B31+B32+B33+
    B34+B35+B36, method = "rf", data = sdfAll, tuneGrid=mtry, trControl=cv)
print(mtry_eval)
plot(mtry_eval)

#Modelo random forest
modelo.arbol.rf <- randomForest(as.factor(class)~B1+B2+B3+B4+B5+B6+B7+B8+B9+B1
0+B11+B12+B13+B14+B15+B16+B17+B18+B19+B20+B21+B22+B23+B24+B25+B26+B27+B28+B29+
B30+B31+B32+B33+B34+B35+B36, method = "rf", data = sdfAll,
  mtry = 10,
  importance = TRUE,
  ntree = 500,
  type="prob")
modelo.arbol.rf
plot(modelo.arbol.rf, main="Modelo, arboles, RF")

#Identificación de los predictores más importantes
class(modelo.arbol.rf) #randomForest
varImpPlot(modelo.arbol.rf, main="Modelo, arboles, RF")

#Salida modelo
modelo.arbol.rf[["type"]] #"classification"
write.table(modelo.arbol.rf[["predicted"]], file = "C:/TESIS/Clasificacion/pre
dicted.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["err.rate"]], file = "C:/TESIS/Clasificacion/rati
o_error.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["confusion"]], file = "C:/TESIS/Clasificacion/con
fusionmatrix.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["votes"]], file = "C:/TESIS/Clasificacion/votes.t
xt", row.names = FALSE)
write.table(modelo.arbol.rf[["oob.times"]], file = "C:/TESIS/Clasificacion/oob
times.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["importance"]], file = "C:/TESIS/Clasificacion/im
portance.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["importanceSD"]], file = "C:/TESIS/Clasificacion/
importanceSD.txt", row.names = FALSE)
write.table(modelo.arbol.rf[["y"]], file = "C:/TESIS/Clasificacion/y.txt", row
.names = FALSE)

#Predicciones
#Procesamiento en paralelo
beginCluster()
```

```
preds_rf1 <- clusterR(imgs, raster::predict, args = list(model = modelo.arbol.
rf))
endCluster()

plot(preds_rf1,main="Clasificación")
print(preds_rf1)
writeRaster(preds_rf1,"C:/TESIS/Clasificacion/Clasificacion.tif")
#End
```

Separabilidad

```
# sepMatrix.R
# Función para calcular matrices de separabilidad (usando la distancia de Jeff
ries-Matusita) para diferentes bandas entre diferentes tipos cultivo.
# Jesús Álvarez Mozos, Pamplona, 2/02/2011

# usa como input una tabla con datos separados por tabulador (por ejemplo Tabl
e.txt) en la que en columnas figuran las diferentes bandas
# la última columna es un código de cultivo que va de 1 a n
# en filas van las observaciones (píxeles o parcelas)

# para cada banda se genera una tabla de salida (por ejemplo sepMatrix_jnVV_1.
txt) que contiene la matriz con la separabilidad para cada par de clases
# también se imprime en pantalla el valor de separabilidad medio para cada ban
da

sepMatrix <- function(tabla) {

# calcular el número de columnas de datos
col_dat <- ncol(tabla)- 1

# bucle para que vaya pasando de columna a columna
for(i in 1:col_dat)
{
# calcular el número de cultivos según los códigos de la última colum
na
ncrop <- max(tabla[,ncol(tabla)])

# crear una matriz de ncropxncrop para cada banda en la que se vayan
poniendo las separabilidades como en una matriz de contingencia
sepMatrix_name <- paste("sepMatrix_", colnames(tabla[i]))
sepMatrix <- matrix(nrow = ncrop, ncol=ncrop)

# bucle para que vaya pasando de cultivo a cultivo
for(j in 1:ncrop)
{

# definir un vector con los datos del cultivo j para la banda
i
Vector.1 <- subset(tabla, Reclase==j, select = i)

# bucle para ir pasando de cultivo a cultivo
for(k in j:ncrop)
{

# definir otro vector con los datos del cultivo k par
a la banda i
Vector.2 <- subset(tabla, Reclase==k, select = i)

# calcular la distancia Jeffries-Matusita según el có
digo de Nikos Alexandris "separability.measures.R":

# convert vectors to matrices in case they are not
Matrix.1 <- as.matrix (Vector.1)
Matrix.2 <- as.matrix (Vector.2)

# define means
mean.Matrix.1 <- mean ( Matrix.1 )
mean.Matrix.2 <- mean ( Matrix.2 )

# define difference of means
mean.difference <- mean.Matrix.1 - mean.Matrix.2
```

```

# define covariances for supplied matrices
cv.Matrix.1 <- cov ( Matrix.1 )
cv.Matrix.2 <- cov ( Matrix.2 )

# define the halfsum of cv's as "p"
p <- ( cv.Matrix.1 + cv.Matrix.2 ) / 2

# calculate the Bhattacharyya index
bh.distance <- 0.125 *
  t ( mean.difference ) *
  p ^ ( -1 ) *
  mean.difference +
  0.5 * log (
    det ( p ) / sqrt (
      det
      ( cv.Matrix.1 ) *
      ( cv.Matrix.2 )
    )
  )

# calculate Jeffries-Matusita
# following formula is bound between 0 and 2.0
jm.distance <- 2 * ( 1 - exp ( -bh.distance ) )

# also found in the bibliography:
# jm.distance <- 1000 * sqrt ( 2 * ( 1 - exp ( -bh.
distance ) ) )
# the latter formula is bound between 0 and 1414.0

# guardar el dato de jm.distance en la matriz de sepa
rabilidad sepMatrix en la fila i columna k
  sepMatrix[j,k] <- jm.distance
}
}

# calcular la separabilidad media para cada banda y mostrarla en pant
alla
pos_sepMatrix <- sepMatrix[(!is.na(sepMatrix)) & sepMatrix>0]
sep_mean <- round (mean(pos_sepMatrix), digits = 3)
cat(paste(colnames(tabla[i]),": ", sep_mean, "\n"))

#convertir el nombre de la tabla a texto para asignarlo como nombre d
e archivo
outputfile_name <- as.character(sepMatrix_name)

# guardar la sepMatrix como .txt
write.table (round (sepMatrix , digits = 3) ,file = paste(outputfile_
name, ".txt") , sep = "\t" , eol = "\n")
}
}

```

RESULTADOS RANDOM FOREST

Parámetros utilizados:

25000 samples

36 predictor

9 classes: '1', '2', '3', '4', '5', '6', '7', '8', '9'

No pre-processing

Accuracy was used to select the optimal model using the largest value.

The final value used for the model was mtry = 10.

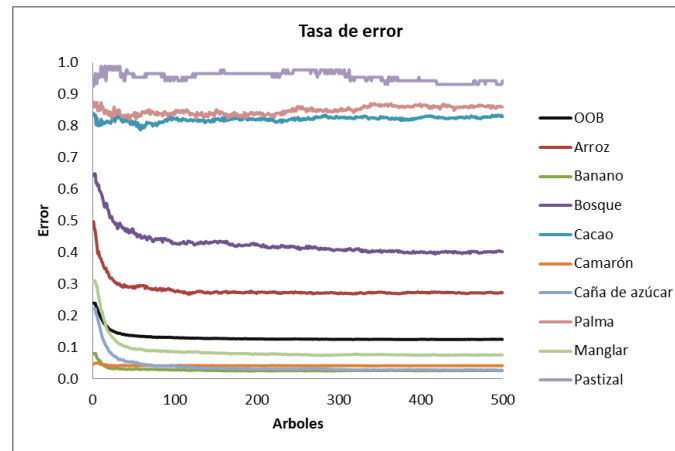
mtry: Number of variables randomly sampled as candidates at each split. For classification (\sqrt{p}) where p is number of variables in x).

mtry	Accuracy	Kappa	mtry	Accuracy	Kappa
2	0.868	0.836	19	0.871	0.840
3	0.871	0.840	20	0.872	0.841
4	0.872	0.842	21	0.871	0.841
5	0.873	0.843	22	0.870	0.839
6	0.873	0.843	23	0.870	0.839
7	0.873	0.842	24	0.870	0.840
8	0.874	0.844	25	0.869	0.838
9	0.874	0.843	26	0.868	0.837
10	0.874	0.844	27	0.868	0.837
11	0.872	0.842	28	0.868	0.837
12	0.874	0.844	29	0.868	0.836
13	0.872	0.842	30	0.867	0.835
14	0.873	0.842	31	0.867	0.836
15	0.873	0.842	32	0.867	0.835
16	0.873	0.843	33	0.865	0.832
17	0.873	0.842	34	0.864	0.832
18	0.873	0.842	35	0.864	0.832

Matriz de confusión RF

Clase	Arroz	Banano	Bosque	Cacao	Camaron	Caña de a.	Palma	Manglar	Pastizal	class.error
Arroz	1310	0	7	17	7	444	7	10	0	0.27
Banano	1	4464	9	4	0	2	0	106	0	0.03
Bosque	5	8	744	40	3	75	2	368	0	0.40
Cacao	23	25	176	164	4	199	6	363	0	0.83
Camaron	12	0	139	26	6821	20	0	104	0	0.04
Caña de a.	94	0	11	16	0	4560	3	7	0	0.03
Palma	25	0	17	43	0	230	65	85	0	0.86
Manglar	13	89	116	23	4	59	3	3734	0	0.08
Pastizal	4	0	26	6	2	36	0	9	5	0.94

err.rate: vector error rates of the prediction on the input data, the i -th element being the (OOB) error rate for all trees up to the i -th



votes: a matrix with one row for each input data point and one column for each class, giving the fraction or number of (OOB) 'votes' from the random forest.

Summary

Clases	Arroz	Banano	Bosque	Cacao	Camaron	Caña de a.	Palma	Manglar	Pastizal	Total
Voto	1780.1	4572.4	1244.3	1060.1	7134.2	4626.3	515.3	3969.5	97.8	25000
Porcentaje	7.1	18.3	5.0	4.2	28.5	18.5	2.1	15.9	0.4	100.0

importance: The first nclass columns are the class-specific measures computed as mean decrease in accuracy. The nclass + 1st column is the mean decrease in accuracy over all classes. The last column is the mean decrease in Gini index.

Banda	Bosque	Cacao	Camaron	Caña de a.	Palma	Manglar	Pastizal	Mean Decrease Accuracy	Mean Decrease Gini
1	0.056	0.009	0.117	0.140	0.023	0.075	0.011	0.104	2481.837
2	0.031	0.011	0.047	0.115	0.020	0.085	0.010	0.079	2288.862
3	0.017	0.001	0.000	0.006	0.004	0.010	0.002	0.004	193.676
4	0.011	0.009	0.015	0.101	0.014	0.038	0.009	0.056	1155.307
5	0.008	0.003	0.006	0.057	0.009	0.040	0.006	0.038	755.849
6	0.003	0.000	0.000	0.013	0.002	0.012	0.005	0.005	167.718
7	0.009	0.006	0.015	0.122	0.015	0.025	0.010	0.047	715.813
8	0.007	0.001	0.002	0.050	0.005	0.047	0.002	0.025	312.050
9	0.003	0.001	0.000	0.029	0.001	0.008	0.002	0.007	176.362
10	0.009	0.007	0.024	0.110	0.008	0.027	0.006	0.045	457.876
11	0.014	0.005	0.009	0.136	0.018	0.061	0.014	0.055	790.964
12	0.004	0.001	0.000	0.014	0.005	0.005	0.004	0.004	162.008
13	0.019	0.014	0.099	0.139	0.017	0.047	0.009	0.083	1033.213
14	0.021	0.010	0.032	0.091	0.013	0.057	0.006	0.059	1271.667
15	0.002	0.002	0.001	0.012	0.002	0.006	0.001	0.004	167.754
16	0.010	0.000	0.013	0.073	0.009	0.039	0.005	0.036	677.783
17	0.009	0.001	0.005	0.054	0.007	0.063	0.005	0.035	441.541
18	0.004	0.001	0.000	0.019	0.005	0.005	0.002	0.006	180.295
19	0.007	0.000	0.009	0.023	0.003	0.026	0.005	0.019	249.570
20	0.011	0.002	0.003	0.053	0.004	0.090	0.003	0.035	471.355
21	0.003	0.000	0.000	0.013	0.003	0.009	0.001	0.005	181.097
22	0.015	0.003	0.010	0.017	0.007	0.034	0.004	0.027	360.895
23	0.012	0.001	0.004	0.055	0.004	0.074	0.007	0.037	455.918
24	0.006	0.001	0.000	0.002	0.001	0.005	0.003	0.002	156.877
25	0.057	0.015	0.033	0.096	0.011	0.046	0.010	0.060	874.004
26	0.006	0.003	0.009	0.093	0.009	0.075	0.015	0.049	814.800
27	0.024	0.002	0.000	0.005	0.006	0.009	0.003	0.005	198.726
28	0.038	0.015	0.008	0.083	0.006	0.038	0.013	0.037	546.583
29	0.006	0.003	0.002	0.030	0.004	0.039	0.002	0.022	291.390
30	0.011	0.001	0.000	0.005	0.002	0.003	0.004	0.003	164.764
31	0.025	0.005	0.057	0.015	0.007	0.029	0.005	0.036	416.069
32	0.008	0.001	0.009	0.013	0.003	0.065	0.004	0.023	405.914
33	0.014	0.001	0.001	0.004	0.003	0.008	0.004	0.003	190.324
34	0.019	0.006	0.099	0.019	0.005	0.026	0.002	0.050	545.711
35	0.008	0.002	0.004	0.037	0.001	0.028	0.007	0.027	416.464
36	0.019	0.001	0.000	0.003	0.003	0.004	0.004	0.003	186.213

importanceSD: The “standard errors” of the permutation-based importance measure. For classification, a p by $n_{class} + 1$ matrix corresponding to the first $n_{class} + 1$ columns of the importance matrix.

Banda	Arroz	Banano	Bosque	Cacao	Camaron	Caña de azúcar	Palma	Manglar	Pastizal	Mean Decrease Accuracy
1	0.001	0.005	0.002	0.001	0.006	0.002	0.001	0.004	0.002	0.002
2	0.001	0.005	0.002	0.001	0.003	0.003	0.001	0.003	0.001	0.002
3	0.000	0.000	0.001	0.000	0.000	0.000	0.000	0.000	0.001	0.000
4	0.001	0.003	0.001	0.001	0.001	0.002	0.001	0.001	0.001	0.001
5	0.001	0.003	0.001	0.001	0.001	0.002	0.001	0.001	0.001	0.001
6	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000
7	0.001	0.002	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
8	0.001	0.003	0.001	0.001	0.000	0.001	0.001	0.001	0.001	0.001
9	0.000	0.000	0.000	0.000	0.000	0.001	0.000	0.000	0.001	0.000
10	0.001	0.003	0.001	0.001	0.001	0.002	0.001	0.001	0.001	0.001
11	0.001	0.003	0.001	0.001	0.001	0.002	0.001	0.001	0.001	0.001
12	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000	0.001	0.000
13	0.001	0.005	0.001	0.001	0.006	0.002	0.001	0.002	0.001	0.002
14	0.001	0.005	0.001	0.001	0.002	0.003	0.001	0.003	0.001	0.002
15	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000
16	0.001	0.003	0.001	0.001	0.001	0.002	0.001	0.002	0.001	0.001
17	0.001	0.003	0.001	0.001	0.000	0.002	0.001	0.001	0.001	0.001
18	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000	0.001	0.000
19	0.001	0.001	0.000	0.000	0.001	0.001	0.001	0.001	0.001	0.000
20	0.001	0.002	0.001	0.001	0.000	0.001	0.001	0.001	0.001	0.001
21	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000
22	0.001	0.003	0.001	0.000	0.001	0.000	0.001	0.001	0.001	0.001
23	0.001	0.003	0.001	0.001	0.000	0.001	0.001	0.001	0.001	0.001
24	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000
25	0.001	0.004	0.001	0.001	0.002	0.001	0.001	0.002	0.001	0.001
26	0.001	0.003	0.001	0.001	0.000	0.002	0.001	0.001	0.001	0.001
27	0.000	0.000	0.001	0.000	0.000	0.000	0.001	0.000	0.001	0.000
28	0.001	0.003	0.001	0.001	0.001	0.001	0.001	0.001	0.001	0.001
29	0.000	0.003	0.001	0.001	0.000	0.001	0.001	0.001	0.001	0.001
30	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.001	0.000
31	0.001	0.003	0.001	0.001	0.004	0.001	0.001	0.002	0.001	0.001
32	0.001	0.002	0.001	0.001	0.001	0.001	0.001	0.002	0.001	0.001
33	0.000	0.000	0.001	0.000	0.000	0.000	0.000	0.000	0.001	0.000
34	0.001	0.003	0.001	0.001	0.006	0.001	0.001	0.002	0.001	0.002
35	0.001	0.004	0.001	0.001	0.000	0.001	0.001	0.001	0.001	0.001
36	0.000	0.000	0.001	0.000	0.000	0.000	0.000	0.000	0.001	0.000