



VNIVERSITAT [ð-] Facultat de Física

Departament de Física de la Terra i Termodinàmica



Tesis Doctoral

Doctorado en Teledetección

Estudio integral de humedales altoandinos
(andean peatlands) con Teledetección y SIG

Memoria dirigida por:
Dr. Jesús Delegido Gómez
Dr. Jochem Verrelst

Memoria presentada por:
Carlos Arturo Jara Santillán
Burjassot, enero de 2022

Resumen

La Reserva de Producción de Fauna Chimborazo (RPFCH) es un ecosistema de alto valor situado en los andes ecuatorianos, ocupado en su mayor parte por turberas, también llamados bofedales o peatlands. El objetivo de esta tesis es el estudio de dichos ecosistemas a partir de una extensa base de datos de campo obtenida en 2016 y usando datos de teledetección óptica y radar y variables topográficas, ambientales y climáticas con SIG. Para ello se analizaron los mejores métodos para el cartografiado de los peatlands en la RPFCH, la estimación del carbono bajo el suelo (COS) en la capa 0-30 cm y la estimación del carbono almacenado en la vegetación calculado a partir de la biomasa.

Como resultado se obtuvo que, comparando Sentinel-2 con Landsat-8, el mejor método para el cartografiado se obtuvo clasificando con Random Forest y usando índices de vegetación con Sentinel-2, siendo SAVI y REDEDGE los índices de mayor importancia. Con ello se ha cartografiado los peatlands en la RPFCH y se ha estimado que el área ocupada por este ecosistema en 2017 fue de 23292 ha.

En cuanto al carbono almacenado en la vegetación, y usando una extensa base de datos de campo de 320 puntos, se probaron 4 modelos de aprendizaje automático con diferentes combinaciones de variables y se obtuvo que el mejor método fue Gaussian Process Regression (GPR) siendo las variables más importantes, por orden, la elevación, la precipitación, la relación VV/VH de Sentinel-1, el índice NBRI y el LAI de Sentinel-2. Para la estimación de cambios temporales del carbono de la vegetación se propone un modelo adicional utilizando únicamente información obtenida de la imagen Sentinel-2. Con ello se cuantificó la pérdida de carbono almacenada por la vegetación del ecosistema entre los años 2017 y 2020 usando solo las bandas de Sentinel-2 y entrenando GPR con los datos de campo, estimando que la cantidad de carbono total de la vegetación fue de 71975 Mg en 2017 y pasó a 59362 Mg en 2020.

Por otra parte, para estudiar el COS, a partir de 320 datos de campo se probaron también los mismos 4 modelos de aprendizaje automático con diferentes combinaciones de variables y se obtuvo que el mejor método fue GPR y que las mejores variables por orden de importancia fueron: la elevación, usos de suelo, temperatura, distancia a ríos, REDEDGE de Sentinel-2 y el band ratio del promedio (VH/VV) de Sentinel-1. Con ello se elaboró el mapa de COS del bofedal de la RPFCH y se calculó el carbono total en la capa de 30 cm de suelo, resultando ser de 13639407 Mg, mostrando la importancia de este ecosistema en cuanto a su capacidad de almacenamiento de carbono.

VNIVERSITAT (ò) VALÈNCIA (ò) Facultat de Física

Departament de Física de la Terra i Termodinàmica



TESIS DOCTORAL

Doctorado en Teledetección

Estudio integral de humedales altoandinos
(andean peatlands) con Teledetección y SIG

Memoria dirigida por:
Dr. Jesús Delegido Gómez
Dr. Jochem Verrelst

Memoria presentada por:
Carlos Arturo Jara Santillán
Burjassot, enero de 2022

El Dr. Jesús Delegido Gómez, Profesor Titular de Universidad adscrito al Departament de Física de la Terra i Termodinàmica de la Facultat de Física de la Universitat de València y el Dr. Jochem Verrelst investigador del Grupo de Laboratory for Earth Observation (LEO) de la Universitat de València.

CERTIFICAN:

Que la presente memoria titulada: “Estudio integral de humedales altoandinos (andean peatlands) con Teledetección y SIG”, presentada por Don Carlos Arturo Jara Santillán para optar al grado de Doctor en Teledetección, ha sido realizada bajo nuestra dirección en el Departament de Física de la Terra i Termodinàmica de la Facultat de Física de la Universitat de València y autorizan su depósito.

Y para que así conste, en cumplimiento de la legislación vigente, firmamos el presente certificado en Burjassot, a 20 de enero de 2022.

Fdo.: Jesús Delegido Gómez

Fdo.: Jochem Verrelst

A Joha, Arturito y Carlita

Agradecimientos

Mi agradecimiento a Dios y a la madre Dolorosa, por darme la fortaleza para poder enfrentar todos los retos presentados, haciéndome sentir siempre su presencia, sobre todo en los momentos más duros.

Al Laboratorio de Procesado de Imágenes, por abrirme las puertas para poder realizar mi investigación, de manera especial al profesor Jesús Delegido por estar siempre pendiente, por impartir sus conocimientos, por su guía y sobre todo por su paciencia. A Jochem Verrelst por su generosidad al compartir con nosotros la herramienta ARTMO y a Gabriel por darse el tiempo de apoyarme en RADAR.

A lo más importante en la vida de Joha y en la mía, mi Arturito y mi Carlita, que llegaron para llenar nuestras vidas y nuestros corazones, que a pesar de lo difícil que resulta a momentos el trabajar, estudiar y estar pendientes de que no les falte nunca nada y cubrir todas sus necesidades, basta una ocurrencia o una sonrisa de ellos, para que todo valga la pena y sea la mejor recompensa.

A mi compañera de vida, mi Johannita, la persona que más admiro en todo el mundo, que hace casi ya doce años que logré llamar su atención, para caminar juntos y formar esta hermosa familia con la que Dios y la madre Dolorosa nos han bendecido, nunca terminaré de agradecerle por todo el esfuerzo y sacrificio que nos entrega día a día, ni de elogiarle por su gran capacidad e intelecto.

A mi querida institución, a la Escuela Superior Politécnica de Chimborazo, en donde pude formarme en mis estudios de pregrado y donde hace un poco más de diez años cumplo mi sueño de ser docente, también por apoyarme para realizar mis estudios doctorales y por financiar el proyecto: “Servicios ecosistémicos de la Reserva de Producción de Fauna Chimborazo”, en donde pude trabajar con Pato, Valita y Artita, compartiendo experiencias enriquecedoras en campo y en laboratorio.

Lista de Acrónimos

AGB	Above Ground Biomass
ARTMO	Automated Radiative Transfer Models Operator
B	Biomasa
BRT	Boosting Regression Tree
BSI	Bare Soil Index
C	Carbono
CART	Classification and Regression Trees
CC	Cantidad de Carbono
CCC	Canopy Chlorophyll Content
CLD	Convención de las Naciones Unidas de Lucha contra la Desertificación
CO	Carbono Orgánico
COT	Carbono Orgánico Total
COS	Carbono Orgánico del Suelo
CO ₂	Dióxido de carbono
CWC	Canopy Water Content
DA	Densidad Aparente
dB	Decibeles
DEM	Digital Elevation Model
ESPOCH	Escuela Superior Politécnica de Chimborazo
EVI	Enhanced Vegetation Index
EW	Extra Wide Swath
fAPAR	fraction of Absorbed Photosynthetically Active Radiation
fVC	fraction of vegetation Cover
GCI	Green Coverage Index
GEI	Gases de efecto invernadero
GNDVI	Green Normalized Difference Vegetation Index
GPP	Gross Primary Production
GPR	Gaussian processes regression
GRD	Ground Range Detected
INAMHI	Instituto Nacional de Meteorología e Hidrología

IW	Interferometric Wide Swath
KRR	Kernel Ridge Regression
LAI	Leaf Area Index
LE	Latent Energy
MLRA	Machine Learning Regression Algorithms
MO	Materia Orgánica
MRCV	Modelo de Regresión para el Carbono de la Vegetación
MSI	Moisture Stress Index
NBRI	Normalized Burned Ratio Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared
OCN	Ocean
OOB	Out of bag
PER	Peso estufa real
PMR	Peso mufla real
QRF	Quantile Regression Forest
RF	Random Forest
REDEDGE	Borde rojo
RFR	Random Forest Regression
RPFCH	Reserva de Producción de Fauna Chimborazo
RS	Remote Sensing
SAR	Synthetic Aperture Radar
SAVI	Soil Adjusted Vegetation Index
SIN	Sistema Nacional de Información
SLC	Single Look Complex
SM	Stripmap
SNAP	Sentinel Application Platform
SOC	Soil Organic Carbon
SWIR	Short Wave Infrared
TWI	Topographic Wetness Index
VHGPR	Variational Heteroscedastic Gaussian Processes Regression
WV	Wave Mode

Contenido

Resumen

Introducción.....	1
1. Características de los humedales altoandinos (peatlands)	11
1.1. Definición y clasificación	11
1.2. Área de cobertura de los peatlands	15
1.3. Importancia de los peatlands	16
1.3.1. A nivel arqueológico	16
1.3.2. Recurso agua	17
1.3.3. Cartografiado de los peatlands	18
1.3.4. Almacenamiento de carbono	19
2. Instrumentación y medidas	23
2.1. Área de estudio	23
2.2. Campañas de medición	29
2.2.1. Medidas para cartografiar peatlands	29
2.2.2. Medidas del carbono de la vegetación	31
2.2.3. Medidas del suelo para COS	32
2.3. Datos de sensores ópticos y SAR	37
2.3.1. Landsat-8	37
2.3.2. Sentinel-2	40
2.3.3. Sentinel-1	42
2.4. Datos topográficos	52
2.5. Datos ambientales	53
2.6. Variables para el cartografiado de los peatlands	58
2.7. Variables para el contenido del carbono de la vegetación y el COS	58
3. Metodología	63
3.1. Métodos de modelado	63

3.1.1. Random Forest Classification	63
3.1.2. Test de regresión (MLRA)	66
3.1.2.1. Gaussian Processes Regression	67
3.1.2.2. Variational Heteroscedastic Gaussian Processes Regression	70
3.1.2.3. Random Forest (TreeBagger)	71
3.1.2.4. Kernel ridge Regression	72
3.2. Entrenamiento de los modelos de clasificación y regresión propuestos	72
3.2.1. Modelos de clasificación propuestos	72
3.2.2. Calibración de los modelos de clasificación propuestos	73
3.2.3. Validación de los modelos de clasificación propuestos	74
3.2.4. Modelos de regresión propuestos	75
3.2.5. Validación de los modelos de regresión propuestos	76
Resultados.....	79
4. Cartografiado de peatlands.....	83
5. Carbono de la vegetación.....	95
5.1. Estimación del carbono de la vegetación, aplicando MLRA de ARTMO	96
5.2. Uso de Sentinel-2 en la detección de cambios temporales	103
5.3. Validación de los productos automáticos	108
6. Carbono bajo el suelo (COS)	113
Conclusiones.....	121
Perspectivas futuras	123
Referencias	125

Introducción

Los humedales proporcionan una amplia variedad de servicios ambientales a nivel mundial, por ello son necesarios mapas detallados del inventario de humedales, para determinar las estrategias de conservación y monitorear eficazmente estos ecosistemas productivos (Mahdianpari et al., 2018). Los humedales se encuentran en todas partes, desde la tundra hasta los trópicos. No se sabe con exactitud que parte de la superficie terrestre está ocupada actualmente por humedales (Ramsar, 2013). Los humedales alto andinos son turberas (peatlands) de montaña tropical que se localizan en los Andes, en los que se acumula materia orgánica conocida como turba (peat), contienen extensos suelos que aún no se han cartografiado o incluido en las estimaciones de carbono (C) global (Hribljan et al., 2017).

El monitoreo de carbono sobre y bajo el suelo es importante para mejorar la comprensión del rol del suelo y la vegetación en el cambio del medio ambiente global. A nivel mundial, las reservas de carbono más grandes se encuentran en zonas críticas como peatlands y humedales, la mayoría de las cuales están en regiones de permafrost y en los trópicos (Köchy et al., 2015). Los peatlands son evaluados por su función como depósitos, sumideros y fuentes de carbono, siendo cada vez más activos e importantes por su dinámica dentro del ciclo global del carbono (Lawson et al., 2015). Los peatlands, almacenan aproximadamente un tercio del carbono del suelo del mundo (Lees et al., 2018). Sin embargo, todavía existen grandes incertidumbres en las estimaciones de stock de C y una comprensión deficiente de la dinámica de C en las escalas de tiempo (Yu, 2012). La variabilidad en las estimaciones de carbono en peatlands se debe a la variación en las definiciones de unidades de suelo, diferencias en las bases de datos de propiedades del suelo, escasez de información sobre el carbono del suelo a profundidades superiores a 1 m y a la variación en su definición (Köchy et al., 2015).

Introducción

Los peatlands son ecosistemas que almacenan una gran reserva de carbono terrestre, por tanto, cualquier cambio en su balance podría provocar grandes cambios en los gases de efecto invernadero (GEI) del planeta. El almacenamiento atmosférico de carbono es de aproximadamente 750 Gt, en comparación con un estimado de 500 ± 100 Gt almacenadas en los peatlands (Yu, 2012). Los depósitos de carbono orgánico del suelo (COS) son susceptibles a la perturbación humana, siendo el cambio de uso del suelo uno de los factores más importantes, lo que ha resultado en una pérdida significativa de sus reservas (Shen et al., 2019; Yang et al., 2016). Las pérdidas repentinas de COS pueden relacionarse con la erosión y degradación de los suelos (Lal, 2005). Por lo cual, la Convención de las Naciones Unidas de Lucha contra la Desertificación (CLD), ha reconocido el mapa de existencias de COS como un indicador para lograr la neutralidad en la degradación de las tierras como objetivo importante para 2030 (IUCN, 2015).

En los últimos años los datos de teledetección han sido utilizados en el cartografiado del COS y del carbono de la vegetación, siendo los de uso más frecuente las imágenes satelitales con sensores ópticos, tal es el caso de las imágenes MODIS, IKONOS, SPOT y Landsat, a través del uso de índices espectrales de la superficie terrestre y vegetación (Lamichhane et al., 2019; Yang et al., 2019). Sin embargo, todavía existen muchos suelos de peatlands que no se han cartografiado o incluido en estimaciones mundiales de carbono, por lo que la ayuda de los sensores remotos facilita estos trabajos (Hribljan et al., 2017).

Los peatlands de montaña se encuentran en áreas que son particularmente propensas a fuertes lluvias y por lo tanto suelen estar muy nublados, lo que puede limitar los datos disponibles para aplicaciones de teledetección óptica en estudios del suelo. (Lees et al., 2018). Alternativamente, los radar de apertura sintética (SAR) como PALSAR, RADARSAT y Sentinel-1, proporcionan datos que son independientes del clima y la luz del día (Hribljan et al., 2017; Yang & Guo, 2019; Yang et al., 2019; Zhou et al., 2020). Los datos de Sentinel-1 podrían ser útiles para estimar las propiedades del suelo en áreas con una densa cobertura vegetal natural

(Yang et al., 2019). Una vía interesante sería considerar combinar datos visibles y del infrarrojo cercano (NIR), con datos de sensores remotos de otras fuentes como SAR (Lees et al., 2018). Los datos de SAR pueden brindar nuevas oportunidades para predecir la distribución espacial de las propiedades del suelo, pero su aplicación en la predicción del contenido de COS aún es limitada y rara vez se informa en la literatura (Zhou et al., 2020). No se ha explorado completamente el uso de los datos SAR en estudios de propiedades internas del suelo, si no para estimar principalmente las propiedades físicas sobre la capa superficial, por lo que el uso de estos datos pueden ser una alternativa en la búsqueda de mejores modelos para la predicción de parámetros del suelo con alta precisión, como en el caso del COS (Han et al., 2017; Hribljan et al., 2017; Yang & Guo, 2019). Por otra parte, Lawson et al., (2015) recomiendan desarrollar métodos láser con LiDAR para cartografiar peatlands y para cuantificación del carbono de la vegetación.

Se han desarrollado métodos para predecir el COS en los últimos años, tales como: regresión lineal mixta, regresión lineal múltiple, regresión ponderada geográficamente y regresión kriging basado en reglas de regresión (Zhou et al., 2020). Además, los métodos desarrollados a partir de máquinas de aprendizaje para predecir el COS se han convertido en un referente (Wang et al., 2018). Algunos estudios han informado que los modelos basados en árboles tienen un mejor rendimiento de predicción de COS, como los árboles de regresión potenciados (BRT) y los bosques aleatorios (Zhou et al., 2020). La utilización de un conjunto de estimadores aplicando Gaussian Processes Regression (GPR) representa un potencial interesante en la estimación de parámetros biofísicos de la vegetación y el carbono orgánico del suelo (Bazi et al., 2014; Camps-Valls et al., 2015; Verrelst et al., 2012; Yu et al., 2016).

La presencia de peatlands tiene alta importancia en el ciclo hidrológico a través de la provisión y regulación hídrica. Se estima que un cambio del uso del suelo tendrá un alto impacto tanto en la calidad de agua como en la regulación. Con la finalidad

Introducción

de adoptar mejores decisiones en relación con el uso y manejo de los servicios ecosistémicos de los peatlands se debe evaluar su importancia para la sociedad humana (Castro, 2011). Los peatlands en limitadas ocasiones se incluyen como una categoría separada en los modelos de percepción remota del flujo de carbono, por lo que se sobreestiman o subestiman (Lees et al., 2018). Se necesitan con urgencia actividades cartográficas rápidas a gran escala para cuantificar la extensión de peatlands y su tasa de degradación, para lo cual es primordial realizar esfuerzos de monitoreo en apoyo de políticas efectivas y gestión sostenible, incluida la cuantificación de carbono a nivel nacional y global (Hribljan et al., 2017). Existe una distribución espacial desigual de los estudios destinados a monitorizar el carbono utilizando sensores remotos (Lamichhane et al., 2019). De 120 estudios revisados entre 2013 y 2021 existe una mayor concentración en países como China, Australia y Estados Unidos. En Ecuador los peatlands son el ecosistema con la mayor cantidad de almacenamiento de carbono durante más de 7000 años dentro del páramo y han demostrado tasas rápidas de acumulación. Sin embargo, la hidrología y el clima regional se enfrenta a un aumento de presión por el cambio de uso de la tierra y cambios en el clima andino (Hribljan et al., 2016), por lo que el presente estudio se centró en los peatlands de la Reserva de Producción de Fauna Chimborazo (RPFCH) en la parte central de los Andes Ecuatorianos, conocidos localmente como turberas o bofedales (Comas et al., 2017; Hribljan et al., 2017).

Los **objetivos generales** del presente estudio fueron: (1) Cartografiar la extensión total de los peatlands en la RPFCH. (2) Estimar el carbono de la vegetación de los peatlands cartografiados. (3) Estimar el carbono orgánico del suelo del horizonte de 0 a 30 cm de los peatlands cartografiados. Los **objetivos específicos** fueron: - Determinar qué imagen óptica tiene mejores resultados para cartografiar peatlands. - Determinar un modelo de clasificación con mayor rendimiento con la imagen óptica con el mejor resultado. - Estimar cambios temporales del carbono de la vegetación con el uso de Sentinel-2. - Validar los productos automáticos obtenidos del software *Sentinel Application Platform (SNAP)*. - Determinar modelos de

regresión óptimos para estimar el carbono de la vegetación y el carbono orgánico del suelo de los peatlands de la RPFCH.

Para cumplir los objetivos propuestos, con el uso de sensores remotos, mediante la evaluación de modelos de clasificación aplicando Random Forest (RF), se valoran comparativamente imágenes Landsat-8 y Sentinel-2 a partir de índices de vegetación, para determinar qué imagen óptica tiene mejores resultados. A partir de la imagen Sentinel-2 que fue la que obtuvo el mejor resultado de clasificación, se valoran comparativamente (variables biofísicas a partir de los productos automáticos obtenidos en *SNAP*, valores de las bandas multispectrales, índices de vegetación y la combinación de los predictores de mayor importancia), para determinar el modelo de clasificación con mejor rendimiento para cartografiar peatlands en la RPFCH. Para todos los modelos de clasificación se usaron áreas identificadas como peatlands en zonas altoandinas del Ecuador. Para la estimación del carbono de la vegetación y del carbono orgánico del suelo en el horizonte de 0 a 30 cm se evaluaron cinco modelos de regresión propuestos, aplicando el test de regresión Machine Learning Regression Algorithm (MLRA). En el modelo 1 (MR1) se usan variables topográficas, a partir del modelo digital de elevación (DEM) del área de estudio; en el modelo 2 (MR2) se usan las variables ambientales del Sistema Nacional de Información del Ecuador (SNI); en el modelo 3 (MR3), 23 productos obtenidos a partir de datos de Sentinel-2; en el modelo 4 (MR4) se usa 22 productos obtenidos a partir de datos multitemporales de Sentinel-1 y el modelo 5 (MR5) integra la combinación de los mejores resultados a través de los predictores hallados en los modelos anteriores. Se usan datos obtenidos en campo (320 puntos) distribuidos en los peatlands de la RPFCH, tanto para el carbono de la vegetación como para el COS del horizonte 0-30 cm. Con el resultado del primer objetivo general (cartografiado de los peatlands identificados) se aplican los resultados del segundo y el tercero. Para la estimación de cambios temporales del carbono de la vegetación se propone un modelo adicional utilizando únicamente las bandas de la imagen Sentinel-2, el mismo que es aplicado a una nueva imagen del

Introducción

año 2020 la más cercana a los meses de las campañas de medición. Para la validación de los productos automáticos se analiza la relación entre lo medido en las campañas y los valores de las variables biofísicas calculados en SNAP.

En el primer capítulo se incluye una descripción y clasificación de los humedales, definiendo de manera particular a los peatlands, destacando su importancia a nivel arqueológico, su relación con el recurso agua, la necesidad de identificarlos e inventariarlos y su relación con los ciclos del carbono.

El capítulo 2 contiene la descripción sobre el área de estudio. También información de las campañas de medida para cartografiar peatlands y para la estimación del carbono de la vegetación, así como también para la estimación del COS en el horizonte de capa superficial de 0 a 30 cm. Además de una descripción detallada de la instrumentación utilizada a nivel de suelo, así como de teledetección y las características de las medidas realizadas. Se define un conjunto de variables a ser evaluadas como posibles indicadores para el cartografiado y la estimación del carbono de la vegetación y del COS en el horizonte de 0 a 30 cm.

En el tercer capítulo se especifican los métodos de clasificación y regresión para el cartografiado de los peatlands y para la estimación del carbono de la vegetación y del COS en el horizonte de 0 a 30 cm de los peatlands. Se definen los modelos tanto de clasificación como de regresión usando las variables definidas en el capítulo anterior.

El cuarto capítulo incluye los resultados de la comparación de los modelos de clasificación, a partir de la información de imágenes de satélite, para evaluar y determinar el mejor modelo de cartografiado de peatlands mediante algoritmos de clasificación.

En el quinto capítulo, se estima cambios temporales del carbono de la vegetación con el uso de Sentinel-2, se valida los productos automáticos calculados en SNAP

y se comparan los resultados de cinco modelos de regresión, seleccionando el mejor de ellos para determinar el carbono almacenado por la vegetación sobre el suelo a partir de los datos de campo de la biomasa de la vegetación de los peatlands.

Para finalizar, en el sexto capítulo a partir de la evaluación de cinco modelos de regresión, se muestran los resultados para obtener una estimación del COS en el horizonte de 0 a 30 cm de los peatlands, comparando información recolectada en campo, con información obtenida a partir de sistemas de información geográfica y teledetección.

Capítulo 1

Características de los humedales altoandinos (andean peatlands)

En el primer capítulo se incluye una descripción y clasificación de los humedales, definiendo de manera particular a los peatlands, destacando su importancia a nivel arqueológico, su relación con el recurso agua, la necesidad de identificarlos e inventariarlos y su relación con los ciclos del carbono.

1. Características de los humedales altoandinos (andean peatlands)

1.1. Definición y clasificación

Los humedales se encuentran entre los ecosistemas más productivos del mundo. Son cuna de la diversidad biológica, proporcionando el agua y la productividad primaria de la que dependen innumerables especies de plantas y animales para sobrevivir. Los humedales son también importantes depósitos de material genético vegetal (Gumbricht et al., 2017). Se estima que el área de humedales en el mundo podría aumentarse a un total de entre 999 y 4.462 millones de hectáreas cuando se tuvieran en cuenta otras fuentes de información. La Convención sobre los humedales Ramsar, es un tratado intergubernamental cuya misión es “la conservación y el uso racional de todos los humedales mediante acciones locales, regionales y nacionales y la cooperación internacional, como contribución al logro del desarrollo sostenible en todo el mundo” (Ramsar, 2013).

Desde una perspectiva continental, América es el mayor contribuyente en extensión a las áreas de humedales, seguido por Asia (Gumbricht et al., 2017). Ecuador, ubicado en América del Sur, cuenta con 19 humedales considerados como espacios Ramsar, es decir, de importancia internacional por su diversidad biológica. Los humedales incluidos en la lista Ramsar pasan a formar parte de una nueva categoría en el plano nacional y la comunidad internacional reconoce su valor significativo, no sólo para el o los países donde se encuentran, sino también para toda la humanidad (Ramsar, 2021). Ecuador ha designado al Complejo de Humedales Cuyabeno Lagartococha Yasuní como su decimonoveno humedal de importancia internacional hasta el momento. El Sitio (Sitio Ramsar núm. 2332) está ubicado en la región biogeográfica del Amazonas y proporciona un corredor que conecta la Reserva de Vida Silvestre Cuyabeno con el Parque Nacional Yasuní, uno de los puntos críticos de biodiversidad más importantes del mundo (Rivas & Vega, 2018).

1. Características de los humedales altoandinos (peatlands)

Los ecosistemas humedales se encuentran en todas partes, desde la tundra hasta los trópicos. La Convención de Ramsar ha adoptado 42 tipos de humedales, mostrados en la Tabla 1.1., agrupados en tres categorías: humedales marinos y costeros, humedales interiores y humedales artificiales. Dentro de los humedales interiores encontramos a los peatlands (Ramsar, 2013). Hasta el momento los peatlands de estudio, ubicados en la RPFCH, aún no han sido considerados en la lista Ramsar.

Tabla 1.1: Sistema de clasificación de Ramsar por tipo de humedal (Ramsar, 2013)

Humedales marinos / costeros	<p>Aguas marinas poco profundas, permanentes en la mayoría de los casos de menos de seis metros de profundidad durante la marea baja. Incluye: bahías marinas y estrechos.</p> <p>Lechos acuáticos submareales marinos, incluye: lechos de algas marinas, lechos de pastos marinos, praderas marinas tropicales.</p> <p>Los arrecifes de coral.</p> <p>Costas marinas rocosas, incluye: islas rocosas de la costa y acantilados marinos.</p> <p>Orillas de arena y fragmentos de roca, incluye: barras e islotes de arena, sistemas de dunas y pantanales de dunas húmedos.</p> <p>Aguas de estuario, incluye: agua permanente de estuarios y sistemas estuarinos de deltas.</p> <p>Lodo intermareal, arena o salares.</p> <p>Marismas intermareales, incluye: marismas, praderas saladas, salazones, marismas elevadas, marismas de agua dulce y salobre de marea.</p> <p>Humedales boscosos intermareales, incluye: manglares, nipah y bosques pantanosos de agua dulce.</p> <p>Lagunas costeras salobres / salinas, lagunas salobres a salinas con al menos una conexión relativamente estrecha con el mar.</p> <p>Lagunas costeras de agua dulce, incluye lagunas deltaicas de agua dulce.</p> <p>Karst y otros sistemas hidrológicos subterráneos, marino / costero.</p>
Humedales interiores	<p>Deltas interiores permanentes.</p> <p>Ríos / arroyos / quebradas permanentes, incluye cascadas.</p> <p>Ríos / arroyos / arroyos estacionales / intermitentes / irregulares.</p> <p>Lagos permanentes de agua dulce (más de 8 ha), incluye grandes lagos en forma de meandro.</p> <p>Lagos de agua dulce estacionales / intermitentes (más de 8 ha), incluye lagos de llanura aluvial.</p>

1. Características de los humedales altoandinos (peatlands)

	<p>Lagos permanentes salinos / salobres / alcalinos.</p> <p>Lagos y llanos estacionales / intermitentes salinos / salobres / alcalinos.</p> <p>Pantanos / estanques salinos / salobres / alcalinos permanentes.</p> <p>Pantanos / estanques estacionales / intermitentes salinos / salobres / alcalinos.</p> <p>Pantanos / estanques permanentes de agua dulce, estanques (menos de 8 ha), marismas y pantanos en suelos inorgánicos, con vegetación emergente anegada durante al menos la mayor parte de la temporada de crecimiento.</p> <p>Pantanos / estanques de agua dulce estacionales / intermitentes en suelos inorgánicos, incluye: pantanos, prados inundados estacionalmente y marismas de juncos.</p> <p>Peatlands no boscosos, incluye arbustos o pantanos abiertos.</p> <p>Humedales alpinos, incluye prados alpinos y aguas temporales del deshielo.</p> <p>Humedales de la tundra, incluye piscinas de tundra y aguas temporales del deshielo.</p> <p>Humedales dominados por arbustos, pantanos de arbustos, pantanos de agua dulce dominados por arbustos, matorrales de arbustos y matorrales de alisos en suelos inorgánicos.</p> <p>Humedales de agua dulce dominados por árboles, incluye: bosques pantanosos de agua dulce, bosques inundados estacionalmente y pantanos boscosos en suelos inorgánicos.</p> <p>Peatlands boscosos, bosques de peatlands.</p> <p>Manantiales de agua dulce, oasis.</p> <p>Humedales geotérmicos.</p> <p>Karst y otros sistemas hidrológicos subterráneos, tierra adentro.</p>
Humedales artificiales	<p>Estanques de acuicultura (por ejemplo, peces / camarones).</p> <p>Estanques, incluye: estanques agrícolas, estanques de ganado y tanques pequeños, (generalmente por debajo de 8 ha).</p> <p>Tierras de regadío, incluye canales de riego y arrozales.</p> <p>Tierras agrícolas inundadas estacionalmente (incluidas praderas o pastos húmedos de gestión intensiva o de pastoreo).</p> <p>Sitios de explotación de sal, salinas, etc.</p> <p>Áreas de almacenamiento de agua, embalses / presas / represas (generalmente más de 8 ha).</p> <p>Excavaciones, fosas de grava / ladrillo / arcilla, pozos temporales y piscinas mineras.</p> <p>Áreas de tratamiento de aguas residuales, granjas de aguas residuales, estanques de sedimentación, estanques de oxidación, etc.</p> <p>Canales y canales de drenaje, acequias.</p> <p>Karst y otros sistemas hidrológicos subterráneos, creados por el hombre.</p>

1. Características de los humedales altoandinos (peatlands)

Los peatlands se definen como cualquier suelo que tenga al menos 30 cm de descomposición o semi descomposición con al menos 50% de materia orgánica (Gumbrecht et al., 2017). Éstos ecosistemas se caracterizan por su capacidad de acumular grandes cantidades de materia orgánica semi descompuesta, conocida como peat, bajo condiciones de saturación de agua permanente (Domínguez & Vega-Valdés, 2015). Aproximadamente la mitad de los humedales del mundo son peatlands y son particularmente vulnerables a las actividades humanas y el cambio climático (León & Reyes, 2018). Los peatlands almacenan entre el 5 y el 20% de las reservas mundiales de carbono brindando una variedad de servicios ecosistémicos. El cambio climático y el cambio del uso de la tierra están degradando a los peatlands, liberando a la atmósfera el carbono almacenado (Mínasny et al., 2019). Como se observa en la Figura 1.1, el peat está compuesto por el **acrotelmo**, que es el horizonte hidrológicamente activo. Las fibras vegetales mantienen allí su textura, activándose la descomposición y la liberación de dióxido de carbono (CO₂) cuando desciende el nivel freático. Esta capa está dominada por plantas hidrófilas con una gran capacidad para retener agua, en ella tienen lugar procesos como la fijación de carbono y la descomposición de la materia orgánica. En la siguiente capa se tiene el **catotelmo**, se encuentra permanentemente saturado y es casi estanco, sólo se incrementa a una tasa menor a 1 mm/año (Domínguez & Vega-Valdés, 2015; Iturraspe, 2010).

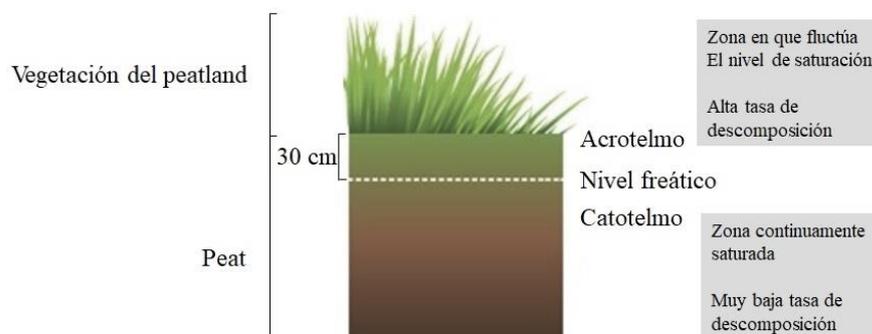


Figura 1.1: Estructura de los peatlands. Adaptado de Domínguez & Vega-Valdés (2015); Iturraspe (2010)

1. Características de los humedales altoandinos (peatlands)

El peat es considerado como un estado primario en la formación del carbón, por lo que su uso tradicional ha sido el energético, en la industria de hidrocarburos y en la agroindustria. También ha sido usado como un eficiente remediador de pasivos ambientales (deuda por daños ambientales) y para controlar derrames de petróleo. Otros usos son: el turismo, la investigación científica y los servicios que proporcionan a los seres humanos que viven en su entorno (Domínguez & Vega-Valdés, 2015). Sin embargo, tal vez la característica más destacable es que los peatlands son libros escritos por la Naturaleza, son archivos de la historia ambiental del final del Cuaternario. Es necesario un esfuerzo científico que nos ayude a leer, interpretar y comprender estos registros y así, recuperar una parte de la historia de los ecosistemas pretéritos (Martínez-Cortizas et al., 2001). Los peatlands se caracterizan por una diversidad biológica específica a nivel genético, de especies, de ecosistemas y de paisaje (Minayeva & Sirin, 2012). Países como Irlanda e Indonesia tienen regulaciones sobre la protección de peatlands, y la Unión Europea, desde el 2021, exige a sus estados que informen sobre la emisión y absorción de GEI de humedales, sin embargo en países como Chile se da prioridad a la explotación sobre la conservación de peatlands (Minasny et al., 2019).

1.2. Área de cobertura de los peatlands

Gumbricht et al., (2017) sugieren a través de su modelo que la estimación del área que cubren los peatlands es de 1,7 millones de km², lo que triplica las estimaciones actuales. Otros estudios indican que los peatlands representan entre el 50 - 70% de los humedales del mundo. Su distribución se concentra en las zonas frías del Hemisferio Norte (Domínguez & Vega-Valdés, 2015). Según estimaciones de Gumbricht et al., (2017), a diferencia de la opinión generalizada actual, sugiere que América del Sur es el mayor contribuyente a la superficie y el volumen de peatlands a nivel mundial (aproximadamente el 44% para ambos), en comparación con el 38% que contiene Asia. Cinco de los quince países con los mayores depósitos de peat según estos datos, se encuentran en América del Sur (**Ecuador**, Surinam, Perú, Brasil y Venezuela). Aun así, es probable que esta clasificación sea una

1. Características de los humedales altoandinos (peatlands)

subestimación, debido a la omisión de peatlands de montaña, extendidos a lo largo de las cadenas montañosas de América Latina.

1.3. Importancia de los peatlands

Los peatlands proporcionan importantes funciones y servicios ecosistémicos, incluyendo la regulación del agua y el clima, la conservación de una biodiversidad específica y el secuestro y almacenamiento de carbono, presentan las áreas, hábitats y refugios mejor conservados para especies biológicas y su estructura está determinada por la humedad, la vegetación del peatland y el peat (Domínguez & Vega-Valdés, 2015; Minayeva & Sirin, 2012). Dada la gran sensibilidad de los peatlands, cualquier tipo de impacto puede poner en peligro su conservación y supervivencia (Fidalgo et al., 2020). Las diferentes actividades humanas (industria, cultivo, expansión urbana) han afectado a cada una de las dimensiones de los peatlands, poniéndolos en grave riesgo y originando cambios inmediatos en su función ecosistémica, de la que sabemos muy poco cómo restaurar (Benavides, 2013).

1.3.1. A nivel arqueológico

Los peatlands tienen una gran importancia **arqueológica**, debido a que conservan restos orgánicos en condiciones semi descompuestas, convirtiéndose en uno de los archivos paleo biológicos más importantes acerca de la historia del paisaje pos glacial. Estudios de peatlands reflejan los cambios paleo ambientales ocurridos entre los últimos 11.000 a 30.000 años y ocupan una posición clave para detectar la desaparición temprana del hielo, así como la crisis climática y la reactivación glacial en torno a los 20.000 años (Domínguez & Vega-Valdés, 2015; Gabov et al., 2017; Musotto, 2013). Los peatlands, al ser sistemas que acumulan materia orgánica en descomposición generando ambientes anóxicos (con poco oxígeno), permiten un elevado grado de preservación de granos de polen y otros microfósiles. El análisis palinológico de peatlands, proporciona elementos para comprender la historia de los ecosistemas actuales, su dinámica y su capacidad de reacción ante el

1. Características de los humedales altoandinos (peatlands)

cambio climático y constituyen importantes reservorios de la información ambiental del pasado. Éstos tienen el mismo valor que las reconstrucciones realizadas a partir de sedimentos lacustres. La integración de la información palinológica con resultados provenientes de otros indicadores (geomorfológicos, paleo magnéticos y micropaleontológicos) permite establecer un modelo paleo climático más preciso (Musotto et al., 2018). Estudios paleo polínicos y su interpretación paleo botánica y paleo climática de depósitos de peat, son también un archivo paleo ambiental, que contiene información sobre los cambios climáticos que ha sufrido la Tierra durante los últimos siglos. Esta información permite generar una base de datos importante para mejorar la sustentación de modelos que nos ayuden a predecir los futuros cambios climáticos. La reconstrucción paleo ambiental elaborada con material proveniente de los peatlands, nos permite dar cuenta de la evolución de la vegetación, clima y paisaje de la región (Domínguez & Vega-Valdés, 2015; Gabov et al., 2017; Musotto, 2013). Lo más probable es que los peatlands hayan estado actuando como sumideros y fuentes de la atmósfera durante al menos varios miles de años y se pueden utilizar para evaluar el intercambio de gases con la atmósfera a lo largo del Holoceno perteneciente a la última glaciación (Klarqvist, 2001). Los resultados obtenidos por Gabov et al., (2017) asignan su vegetación inicial a períodos de formación del peat en el Holoceno y como marcadores de la respuesta del permafrost de los peatlands a los cambios climáticos en latitudes altas.

1.3.2. Recurso agua

Nuestra creciente demanda y uso excesivo de **agua** ponen en peligro el medio ambiente de los peatlands. El incremento de la demanda y suministro del agua para consumo y agricultura, así como el incremento de actividades antrópicas contribuyen a la degradación de los peatlands. A causa de ello se ve reducido el acceso al agua potable, la salud, la producción de alimentos, el desarrollo económico y la estabilidad geopolítica. Incluso con los intentos actuales de mantener caudales de agua para los ecosistemas, la capacidad de los peatlands para continuar entregando beneficios para las personas y la biodiversidad, incluidos el

1. Características de los humedales altoandinos (peatlands)

agua limpia y confiable, se ve disminuida. Es necesario fortalecer la legislación sobre gestión del agua para la conservación de humedales y peatlands. Las múltiples funciones de los ecosistemas de peatlands y su valor para la humanidad han sido cada vez más entendidos y documentados en los últimos años. Esto ha llevado a grandes gastos en la restauración hidrológica y biológica, para recuperar las funciones de los peatlands perdidos o degradados, pero no es suficiente, hay que mejorar prácticas a una escala global significativa por parte de los líderes mundiales, para hacer frente a la acelerada crisis del agua y los efectos del cambio climático. Los responsables de la formulación de políticas y la gestión, con frecuencia toman decisiones de desarrollo basadas en cálculos simples de los pros y contras monetarios de las propuestas ante ellos y no de la importancia de los peatlands para el medio ambiente (Gumbrecht et al., 2017).

1.3.3. Cartografiado de los peatlands

El **conocimiento y la cartografía** actual de los peatlands a nivel mundial son deficientes, están fragmentados, cubren una superficie relativamente pequeña (alrededor de 3% a nivel mundial) y a menudo se pasan por alto en estudios de suelos a gran escala (Minasny et al., 2019). Un problema fundamental al mapear humedales y peatlands es la falta de criterios estandarizados por los cuales se definen e identifican (Gumbrecht et al., 2017). Actualmente no existe un mapa de peatlands confiable y de alta resolución del mundo, es necesario precisar definiciones y un conjunto coherente de clases de peatlands en todos los países, así como el reconocer los mapas generados hasta el momento. Los retos técnicos están en distinguir peatlands de humedales y suelos de permafrost que contienen peatlands. Si bien el cartografiado del peatlands a escala mundial y nacional es importante, la cartografiada digital de suelos también es útil para estudios detallados de suelos en áreas prioritarias. Esto requiere imágenes de alta resolución de detección remota (Minasny et al., 2019). Por lo antes mencionado, la necesidad de desarrollar mapas robustos, comparables y detallados de humedales y peatlands no podría ser más urgente (Gumbrecht et al., 2017). El uso de la cartografía precisa de peatlands es esencial para su protección y restauración dentro de la estimación

1. Características de los humedales altoandinos (peatlands)

del almacenamiento de carbono en el suelo y el apostar por estrategias a favor de la mitigación al cambio climático para bajar las emisiones de carbono conforme al Acuerdo de Paris (Minasny et al., 2019).

1.3.4. Almacenamiento de carbono

Los peatlands son reconocidos a nivel mundial como un recurso económico y ecológico por contribuir al **almacenamiento de carbono** atmosférico, siendo la función de sumidero de carbono la que ha cobrado mayor importancia. De ahí la relevancia actual de conservarlos para prevenir el aumento de las emisiones de GEI y el calentamiento global (Domínguez & Vega-Valdés, 2015). Las estimaciones de peatlands realizadas por Gumbrecht et al. (2017), evidenciarían el concepto erróneo actual de la contribución de los peatlands tropicales al balance mundial de carbono, con volúmenes de peat tropical que duplican las estimaciones actuales. Esto tiene grandes implicaciones para el papel de los humedales y peatlands pantropicales en los cálculos globales de GEI, con grandes riesgos de aumento de emisiones tanto por conversiones de tierras como por resultado de circuitos de retroalimentación en el sistema climático (Gumbrecht et al., 2017). La degradación de los peatlands es responsable de la liberación de 2 a 3 billones de toneladas de CO₂ al año. Como los peatlands pueden convertirse en fuentes importantes de almacenamiento de carbono, estos ecosistemas pueden ser dignos de protección y restauración en el siguiente tratado mundial sobre el clima (Domínguez & Vega-Valdés, 2015). Existe una considerable incertidumbre sobre la extensión espacial de los peatlands y su almacenamiento de Carbono, tanto a nivel nacional como mundial, con estimaciones del almacenamiento globales que van desde 113 a 612 Gt. La calibración local de observaciones de campo y covariables junto a métodos de teledetección es esencial para elaborar mapas de peatlands y estimaciones de carbono más precisos (Minasny et al., 2019).

Capítulo 2

Instrumentación y medidas

El segundo capítulo contiene información sobre el área de estudio, la descripción de la instrumentación utilizada en las campañas de medida, tanto en la toma de muestras in situ como de su proceso en laboratorio (a nivel de suelo como de teledetección). También se detallan las características de las medidas realizadas.

Contiene además la descripción de los satélites utilizados y sus instrumentos de medida, así como también del procesado de las imágenes para la obtención de datos en la definición de las variables utilizadas.

2. Instrumentación y medidas

2.1. Área de estudio

El presente estudio se extiende sobre un área de 53560 hectáreas en los Andes septentrionales ecuatorianos, en la Reserva de Producción de Fauna Chimborazo (RPFCH) en las provincias de Chimborazo, Tungurahua y Bolívar como se muestra en la Figura 2.1. Las coordenadas centrales son: 1° 30' S, 78° 51' W y altitudes que van desde los 3800 hasta los 6268 msnm (Ministerio del Ambiente, 2014).

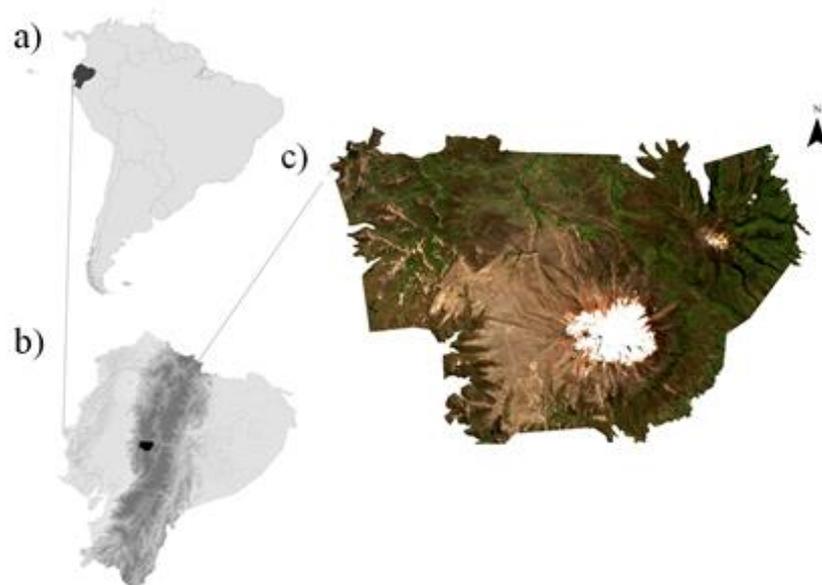


Figura 2.1: Localización del área de estudio. a) Sudamérica, b) Ecuador, c) RPFCH

El clima es frío, con variaciones de temperatura media mensual que oscilan entre 2 y 5 °C, la humedad relativa es elevada entre 72 a 82% y la precipitación es variable,

2. Instrumentación y medidas

estacionaria e interanual significativa, con un promedio anual de 846 mm (ver Figura 2.2). La temporada de lluvia (invierno) ocurre entre diciembre y junio y la temporada seca (verano) de julio a noviembre (Inhami, 2019; Jara et al., 2019).

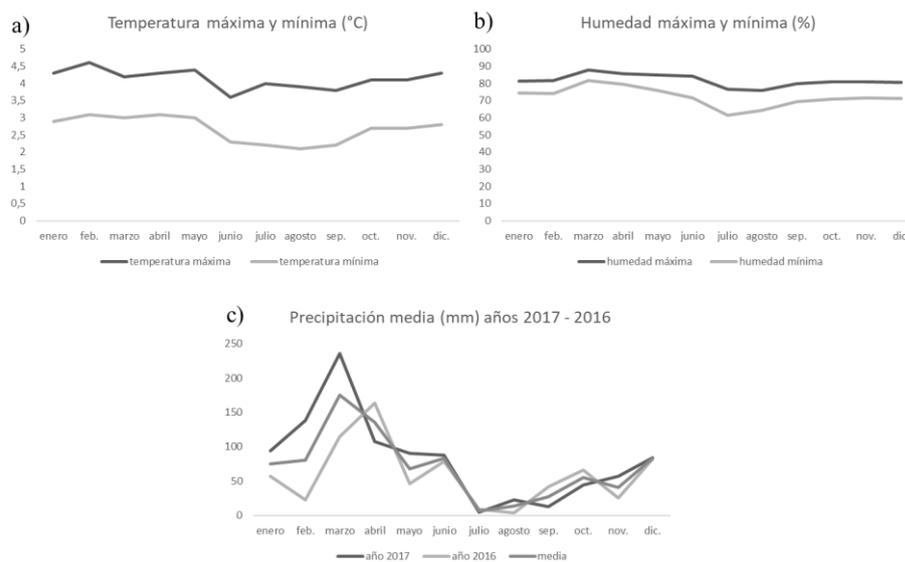


Figura 2.2: Condiciones climáticas del área de estudio de los años 2016 y 2017. a) Temperatura máxima y mínima, b) Humedad máxima y mínima y c) Precipitación media (Inhami, 2019; Jara et al., 2019)

En la zona de estudio puede haber peatlands en toda el área, por lo que se cuenta con 16 zonas de entrenamiento (Figura 2.3 y Tabla 2.1) caracterizadas como peatlands por Andrade, (2016) y Díaz, (2015), a través del proyecto: “Evaluación de los servicios ecosistémicos de la Reserva de Producción de Fauna Chimborazo” de la Escuela Superior Politécnica de Chimborazo (ESPOCH) denominado SIV 25, considerando los siguientes criterios: 1) Altitud: menos de 4100 msnm “bajos” y mayores a 4101 msnm “altos”; 2) Unidad hidrográfica: cuenca del río Llangana,

2. Instrumentación y medidas

cuenca del río Pastaza, cuenca del río Chimbo y cuenca del río Chambo; 3) Estado de alteración por factores antrópicos identificados a través de mapas de avance de actividades pecuarias: intervenidos y no intervenidos (Andrade, 2016).

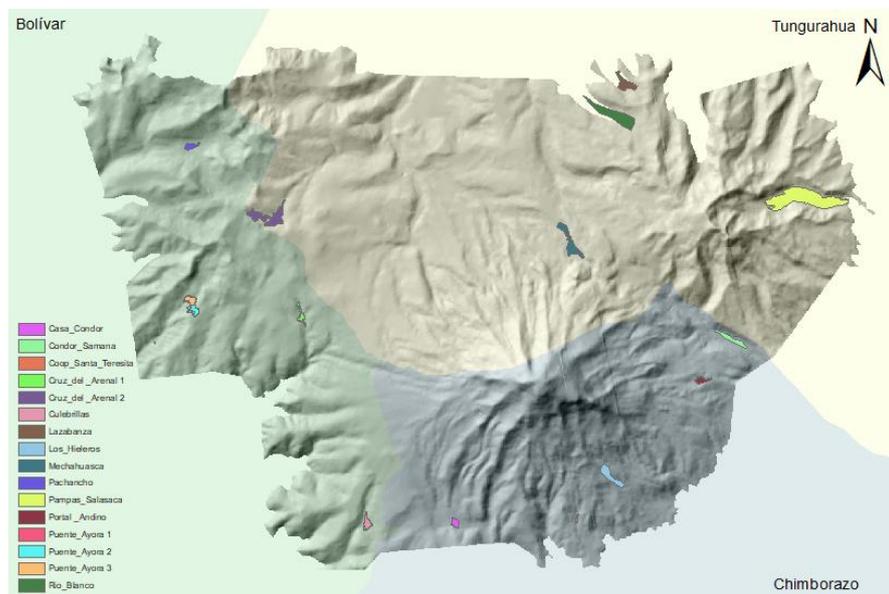


Figura 2.3: Peatlands de entrenamiento por provincias, para clasificación (Andrade, 2016; Díaz, 2015)

Por su taxonomía se diferencian cuatro tipos de suelos (Histosoles, Entisoles, Inceptisoles y Mollisoles) capaces de almacenar carbono orgánico (GIZ, 2018). Debido a que no existe un catastro de los peatlands, estos no se encuentran definidos dentro de la clasificación de ecosistemas definidos por el Ministerio del Ambiente del Ecuador (MAE). Por tanto, actualmente los peatlands caracterizados en zona de estudio, se encuentran distribuidos dentro de 3 de los 8 tipos de ecosistemas definidos por el MAE. (1) Herbazal inundable del Páramos (HsSn04).- Se encuentra a una altitud desde los 3300 a los 4500 msnm, son herbazales inundables en los que

2. Instrumentación y medidas

existen especies que forman cojines o parches aislados de vegetación flotante, esta vegetación azonal del páramo está presente donde existe un balance hídrico positivo, es decir las pérdidas por corrientes y evapotranspiración son menores que las entradas por precipitación o escorrentía. (2) Herbazal húmedo montano alto superior del Páramo (HsSnO3).- En una altitud desde los 3500 a los 4200 msnm, son herbazales abiertos, que se encuentran dominados por especies de los géneros *Stipa*, *Senecio* y *Plantago*, se encuentran en enclaves volcánicos en el fondo de valles glaciares. (3) Herbazal ultrahúmedo subnival del Páramo (HsNnO2).- A una altitud de 4400 a 4900 msnm, son arbustos postrados o almohadillas dispersas, presentan gran cantidad de humedad y las familias dominantes son Asteraceae y Poaceae (Ministerio del Ambiente, 2014).

Tabla 2.1: Elevación, extensión, ubicación por provincias y clasificación ecológica de los peatlands (Andrade, 2016; Ministerio del Ambiente, 2014)

PEATLANDS	Elevación m.s.n.m.	Extensión (Ha)	Provincia	Tipo de Ecosistema
Casa_Condor	4043	10,15	Chimborazo	1
Condor_Samana	4059	24,48	Chimborazo	1
Coop_Santa_Teresita	3839	2,41	Chimborazo	1
Cruz_del_Arenal 1	4081	12,03	Bolívar	1
Cruz_del_Arenal 2	4312	56,02	Bolívar	1
Culebrillas	4159	13,40	Bolívar	1
Lazabanza	4039	30,11	Tungurahua	1
Los_Hieleros	4233	30,65	Chimborazo	1
Mechahuasca	4314	39,86	Tungurahua	3
Pachancho	4079	10,41	Bolívar	1
Pampas_Salasaca	3840	177,84	Tungurahua	1
Portal_Andino	4134	11,42	Chimborazo	1
Puente_Ayora 1	3867	0,33	Bolívar	1
Puente_Ayora 2	4108	13,86	Bolívar	1
Puente_Ayora 3	4145	13,80	Bolívar	2
Rio_Blanco	4153	73,67	Tungurahua	2

El ecosistema más extenso de la RPFCH es el Herbazal húmedo montano alto superior del Páramo, que representa un tercio de su superficie, además, representa alrededor del 50% de la superficie de este ecosistema en todo el país, por lo que su conservación se considera prioritaria (Ministerio del Ambiente, 2014). Los peatlands en estudio se encuentran en terrenos planos e inclinados en fondos de valles asociados a microcuencas y fuentes de agua, por tanto, la hidrología es principalmente agua subterránea, influenciadas por los glaciares Cariguairazo y Chimborazo. Este último es un volcán inactivo, y es el punto más alejado del centro de la Tierra, con un radio de 6384,4 kilómetros, superando en 1,8 kilómetros al Everest como se observa en la Figura 2.4 (Castro Izurieta, 2016).

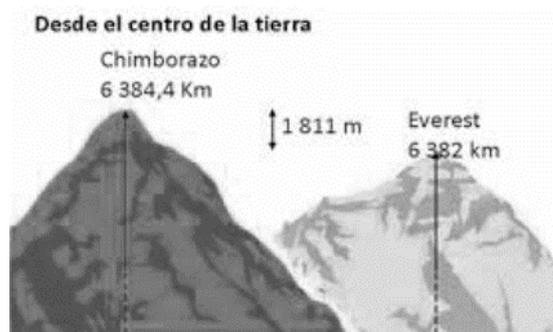


Figura 2.4: Diferencia de altura entre el volcán Chimborazo y el Monte Everest desde el centro de la Tierra (Castro Izurieta, 2016)

La cobertura vegetal es densa y está conformada por comunidades naturales mixtas de turberas, esporádicos charcos de agua y vegetación de cojín, dando origen a un suelo orgánico profundo y turboso. Todos los factores descritos inciden en la vegetación de los peatlands, principalmente en la permanencia y crecimiento de su cobertura vegetal (Jara et al., 2019). De acuerdo al inventario de flora del Proyecto SIV 25, como se muestra en la Figura 2.5, se identificó que las especies más comunes en los peatlands de la RPFCH pertenecen a la familia de las Asteráceas, Poáceas y Plantagináceas. Las especies que pertenecen a los órdenes dominantes, son plantas de tipo herbáceas, como *Lucilia conoidea*, *Distichia muscoides*, y en

2. Instrumentación y medidas

mayor porcentaje *Plantago rígida*. Esta última es conocida comúnmente como almohadilla o musgo, son hierbas que forman grandes montículos, con hojas en forma de roseta que llegan a medir hasta 3 cm de largo, y su función es la de almacenamiento de agua. En la cadena trófica, las almohadillas ocupan el nivel de productor, y mantienen una relación intraespecífica de asociación al distribuirse en montículos de 1 m de diámetro aproximadamente. Estos montículos constituyen, la mayor parte de las veces, las coberturas típicas de los peatlands donde se crea el hábitat de varios organismos acuáticos, entre ellos microorganismos y anfibios. Además, estos sitios son bebederos de aves y mamíferos, principalmente de la vicuña (*Vicugna vicugna*), especie emblemática de los Andes, generando así una relación de comensalismo (Andrade, 2016; Frey, 2017; Lozano, 2017).

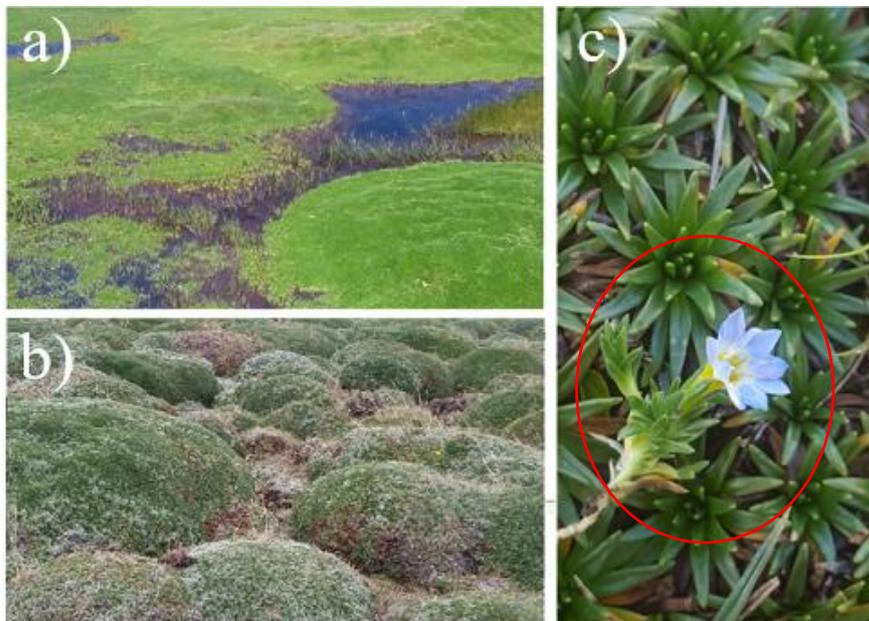


Figura 2.5: Cobertura vegetal representativa de la RPFCH. a) *Distichia muscoides*, b) *Plántago rígida* y c) *Gentiana sedifolia*.

2.2. Campañas de medición

Las campañas de medición y los análisis en laboratorio de las muestras recolectadas, se realizaron con el respaldo del Proyecto SIV 25. Lo que permitió generar la base de datos de clasificación, así como también la de carbono orgánico del suelo y la de carbono de la vegetación, que constituyen los elementos más importantes en el desarrollo y cumplimiento de los objetivos de la presente investigación.

2.2.1. Medidas para cartografiar peatlands

Los 16 peatlands de entrenamiento identificados en la RPFCH fueron clasificados con el fin de conocer su estado de conservación (Tabla 2.2): a) 11 peatlands fueron categorizados como “Intervenidos”, b) los 5 peatlands restantes se categorizaron como “Medianamente conservados”. Una tercera categoría (categoría c) fue realizada a partir de los peatlands “Medianamente conservados” (categoría b), seleccionando 20 áreas con excelente grado de conservación de 30×30 metros, dando lugar a los peatlands “Conservados” (Granizo et al., 2006). Las 20 áreas fueron identificadas mediante un muestreo aleatorio estratificado *in situ* con salidas de medición del 27 de julio al 8 de agosto de 2017 como se muestra en la Tabla 2.2 (Jara et al., 2019). La discriminación se usó para comparar y evaluar las imágenes Landsat-8 y Sentinel-2, en la determinación y cartografiado de los peatlands de la zona de estudio.

Tabla 2.2: Discriminación (intervenidos y medianamente conservados) de los 16 peatlands y 20 zonas de estudio (Jara et al., 2019)

Peatlands	Intervenidos (11 áreas)		
	Cuenca hidrográfica	Perímetro (m)	Área (ha)
Casa Cóndor	Río Llangana	1389	10,15
Coop. Santa Teresita	Río Chambo	1050	2,41
Culebrillas	Río Llangana	2236	13,40
Portal Andino	Río Chambo	2121	11,42
Puente Ayora 1	Río Chimbo	240	0,33

2. Instrumentación y medidas

Cóndor Samana		Río Chambo	3280	24,48
Cruz del Arenal 1		Río Llangana	3175	12,03
Puente Ayora 2		Río Chimbo	2896	13,86
Pachancho		Río Chimbo	1635	10,41
Lazabanza		Río Pastaza	3030	30,12
Puente Ayora 3		Río Chimbo	2389	13,80
Medianamente conservados (5 áreas)				
Peatlands		Cuenca hidrográfica	Perímetro (m)	Área (ha)
Los Hieleros		Río Chambo	3152	30,65
Cruz del Arenal 2		Río Llangana	7598	56,02
Pampas Salasaca		Río Pastaza	9380	177,89
Río Blanco		Río Pastaza	5484	73,67
Mechahuasca		Río Pastaza	5104	39,87
Conservados (20 zonas)				
Peatlands	Área de estudio	Cuenca hidrográfica	Perímetro (m)	Área (ha)
Cruz del Arenal 2 (Bolivar)	CA1	Río Llangana	493	0,55
	CA2	Río Llangana	138	0,11
	CA3	Río Llangana	546	0,55
	CA4	Río Llangana	705	1,85
	CA5	Río Llangana	313	0,27
	CA6	Río Llangana	908	1,09
	CA7	Río Llangana	256	0,19
	CA8	Río Llangana	486	0,49
Los Hieleros (Chimborazo)	LH	Río Chambo	217	0,06
Pampas Salasaca (Tungurahua)	PS1	Río Pastaza	848	1,04
	PS2	Río Pastaza	110	0,05
	PS3	Río Pastaza	560	0,98
	PS4	Río Pastaza	133	0,10
	PS5	Río Pastaza	480	1,01
	PS6	Río Pastaza	148	0,11
	PS7	Río Pastaza	306	0,38
Río Blanco (Tungurahua)	RB1	Río Pastaza	1232	4,80
	RB2	Río Pastaza	362	0,59
	RB3	Río Pastaza	426	0,69
Mechahuasca (Tungurahua)	MCH	Río Pastaza	158	0,12

2.2.2. Medidas del carbono de la vegetación

Para el estudio del carbono de la vegetación se hizo una serie de campañas de campo para la medida de la biomasa (AGB) en las que se tomaron 320 muestras de vegetación (Figura 2.7). En cada uno de los 16 peatlands se recogieron 20 muestras, cada una de ellas en un área de 0,25 m² como se muestra en la Figura 2.6. Las campañas de campo fueron realizadas entre los meses de noviembre del 2016 y febrero del 2017. Chimner et al. (2014) sugieren tomar varias muestras discretas a lo largo del total del peatland para estimaciones de carbono de la vegetación. Mediante la aplicación del método destructivo, se obtuvo el peso húmedo y se secaron las muestras durante 3 días a una temperatura de 60° para obtener el peso seco, determinando así la biomasa (Frey, 2017). Se asume que la concentración de carbono de la vegetación de los peatlands es del 50% del AGB (Draper et al., 2014; Rüginitz et al., 2009; Turunen et al., 2002), por lo que se multiplicó por el factor de 0,5 obteniendo la cantidad de carbono por muestra. La Tabla 2.3 muestra el valor mínimo, máximo y la media de cada peatland.



Figura 2.6: Área de 0,25 m² para la toma de muestras de la vegetación.

2. Instrumentación y medidas

Tabla 2.3: Biomasa y carbono de la vegetación en las muestras de campo. *B* biomasa en gramos, *C* carbono en ($\frac{Mg}{ha}$)

PEATLANDS	B (g)	B (g)	B (g)	C($\frac{Mg}{ha}$)	C ($\frac{Mg}{ha}$)	C ($\frac{Mg}{ha}$)
	MIN	MAX	MEDIA	MIN	MAX	MEDIA
Casa_Condor	17	170	51,45	0,34	3,40	1,03
Condor_Samana	34	238	122,50	0,68	4,76	2,45
Coop_Santa_Teresita	34	85	58,65	0,68	1,70	1,17
Cruz_del_Arenal 1	11	110	49,50	0,22	2,20	0,99
Cruz_del_Arenal 2	10	137	54,30	0,20	2,74	1,09
Culebrillas	1	123	44,30	0,02	2,46	0,89
Lazabanza	19	252	127,85	0,38	5,04	2,56
Los_Hieleros	12	146	58,10	0,24	2,92	1,16
Mechahuasca	10	83	27,75	0,20	1,66	0,56
Pachancho	5	296	42,40	0,10	5,92	0,85
Pampas_Salasaca	219	785	354,65	4,38	15,70	7,09
Portal_Andino	50	434	138,30	1,00	8,68	2,77
Puente_Ayora 1	28	184	76,00	0,56	3,68	1,52
Puente_Ayora 2	6	71	25,55	0,12	1,42	0,51
Puente_Ayora 3	5	129	26,25	0,10	2,58	0,53
Rio_Blanco	51	152	89,65	1,02	3,04	1,79

2.2.3. Medidas del suelo para COS

Para determinar el carbono orgánico del suelo, se obtuvieron 320 muestras de campo (Figura 2.7) en el horizonte superficial, aplicando el método del barreno a una profundidad de 30 cm (Figura 2.8), tomando 20 muestras de suelo por cada uno de los 16 peatlands de la RPFCH.

2. Instrumentación y medidas

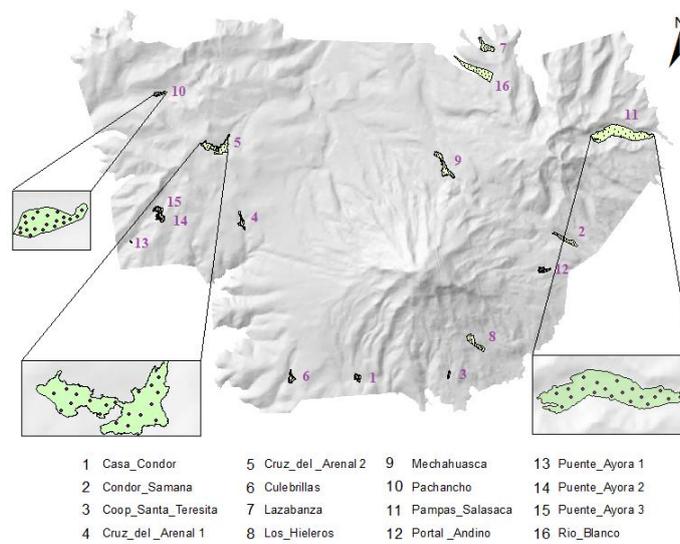


Figura 2.7: Puntos de muestreo del carbono de la vegetación y el COS



Figura 2.8: Toma de muestras del suelo aplicando el método del barreno

2. Instrumentación y medidas

Se cumplió con el siguiente procedimiento: con el uso de una balanza analítica, se pesan 5 g de cada muestra, se colocan en cápsulas de cerámica y se introducen en la estufa a 105 °C durante 24 horas para eliminar la humedad existente. El peso de la cápsula vacía es registrado (*peso cápsula*), también el peso de la cápsula con los 5 g de suelo, y el peso de la cápsula con la muestra después del proceso de secado en la estufa (*peso estufa*). Las cápsulas son llevadas al proceso de calcinación en la mufla a 450 °C durante 15 minutos, se retiraron las cápsulas de la mufla y se registró el nuevo peso (*peso mufla*) como se ve en la Figura 2.9.

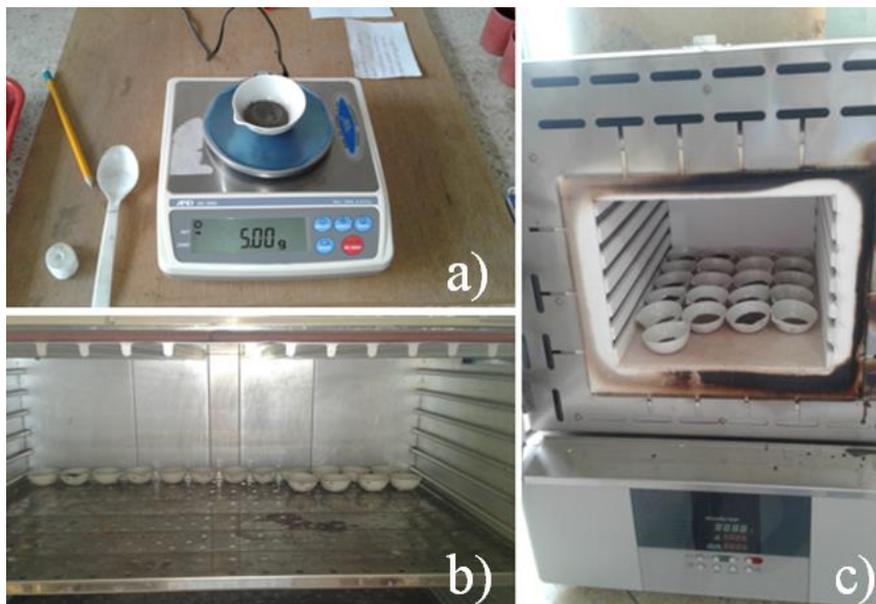


Figura 2.9: Análisis de laboratorio de las muestras de suelo, a) balanza analítica, b) estufa, c) mufla

El porcentaje de materia orgánica (%MO) de las muestras se obtiene usando los pesos obtenidos mediante la expresión 2.1. El COS contenido en las muestras de suelo es expresado en %COS a partir del %MO mediante la expresión 2.2.

$$\%MO = \left(\frac{per - pmr}{per} \right) * 100 \quad 2.1$$

Donde el peso de la estufa real (*per*) = *peso estufa* - *peso cápsula*; y el peso de la mufla real (*pmr*) = *peso mufla* - *peso cápsula* que es el valor de la materia inorgánica.

$$\%COS = \%MO * 0,58 \quad (\text{Lozano, 2017}) \quad 2.2$$

Para calcular el carbono orgánico total se aplica la siguiente expresión (Nadle et al., 2001):

$$COT = \frac{\%COS}{100} * DA \left(\frac{g}{cm^3} \right) * \text{espesor horizonte orgánico (cm)} \quad 2.3$$

Donde la densidad aparente (DA) se calcula dividiendo el peso seco real (*g*) entre el volumen del cilindro (cm^3) y el *espesor horizonte orgánico* viene a ser la profundidad de la muestra (30 cm). Los datos de COT obtenidos en $\frac{g}{cm^2}$, se convirtieron a $\frac{Mg}{ha}$ multiplicándolo por 100.

El contenido de COT de las 320 muestras tienen un valor mínimo de $0,06 \frac{Mg}{ha}$ y un máximo de $706,07 \frac{Mg}{ha}$, por tal motivo, se aplicó a los resultados el cálculo del logaritmo natural mejorando su distribución para su uso en los análisis posteriores (Zhou et al., 2020), como se ve en la Tabla 2.4.

2. Instrumentación y medidas

Tabla 2.4: Carbono orgánico del suelo de las 20 muestras por peatland, a una profundidad de 30 cm, %COS porcentaje carbono, COT ($\frac{Mg}{ha}$) carbono en megagramos por hectárea, LnCOT ($\frac{Mg}{ha}$) logaritmo natural del carbono.

PEATLANDS	%COS MAX	%COS MIN	%COS MEDIA	COT ($\frac{Mg}{ha}$) MAX	COT ($\frac{Mg}{ha}$) MIN	COT ($\frac{Mg}{ha}$) MEDIA	LnCOT ($\frac{Mg}{ha}$) MEDIA
Casa_Condor	3,06	0,25	0,75	16,03	1,48	5,01	1,61
Condor_Samana	51,97	17,55	33,09	416,97	132,88	247,09	5,51
Coop_Santa_Teresita	23,78	0,27	8,36	298,28	1,40	75,25	4,32
Cruz_del_Arenal 1	62,70	0,36	12,99	437,56	4,15	103,17	4,64
Cruz_del_Arenal 2	56,96	1,73	16,74	350,74	18,01	105,50	4,66
Culebrillas	15,01	0,36	2,82	176,58	0,06	29,36	3,38
Lazabanza	64,54	1,11	17,76	499,30	9,56	121,71	4,80
Los_Hieleros	63,92	11,53	26,37	385,93	84,71	183,40	5,21
Mechahuasca	74,88	4,21	22,80	706,07	21,42	193,58	5,27
Pachancho	4,24	0,44	1,65	46,30	4,61	14,08	2,64
Pampas_Salasaca	33,92	0,86	9,02	363,19	8,42	91,39	4,52
Portal_Andino 2	3,92	0,89	2,03	34,31	9,81	18,61	2,92
Puente_Ayora 1	5,93	1,17	3,04	30,82	8,84	20,71	3,03
Puente_Ayora 3	18,60	1,75	3,70	60,85	8,86	22,30	3,10
Puente_Ayora	19,54	0,88	6,88	91,25	11,64	40,41	3,70
Rio_Blanco	19,03	1,23	6,92	131,44	10,92	47,93	3,87

2.3. Datos de sensores ópticos y SAR

2.3.1. Landsat-8

Se ha utilizado la imagen Landsat-8 obtenida mediante el sensor Operational Land Imager (OLI) del 20 de septiembre de 2017 (Figura 2.10), con un nivel de procesamiento L1T (con corrección radiométrica y geométrica mediante la incorporación de puntos de control en tierra y orto rectificación a través del DEM), descargada del visualizador global EarthExplorer de la USGS de los Estados Unidos (<https://glovis.usgs.gov/>).

La imagen pasó por un proceso de calibración radiométrica para obtener valores de radiancia en la parte superior de la atmósfera (TOA) y por un proceso de corrección atmosférica mediante la conversión a los valores de reflectancia, en donde se pudo rectificar las unidades de radiancia de los archivos multiespectrales, aplicando la herramienta FLAASH Atmospheric Correction con el software *ENVI 5.1*.

El proceso de corrección fue necesario para eliminar la dispersión atmosférica en función de la radiancia reflejada por el dosel o la superficie de la tierra y la radiación que se dispersa por la atmósfera antes de llegar al sensor (Ahmed & Akter, 2017; Jara et al., 2019).

La imagen Landsat-8 fue utilizada en el proceso para la cartografía de los peatlands, utilizando para ello el cálculo de cinco índices espectrales de vegetación: NDVI, SAVI, NDWI, WDRI y EVI2 (incluidos en la Tabla 2.5 junto a los usados con Sentinel-2), con el software *ENVI 5.1*. Se seleccionaron estos índices basándonos en el estudio de Ayala-Izurieta et al., (2017) debido a la similitud de las zonas en cuanto a su ubicación geográfica y clima.

2. Instrumentación y medidas

Tabla 2.5: Índices de vegetación usados. Adaptado de Jara et al., (2019)

Índice	Descripción	Ecuación	Bandas	
			Landsat-8	Sentinel-2
NDVI	Índice de vegetación normalizado (Rouse et al., 1986)	$\frac{(NIR - R)}{(NIR + R)}$	$\frac{(b5 - b4)}{(b5 + b4)}$	$\frac{(b8 - b4)}{(b8 + b4)}$
SAVI	Índice de vegetación ajustado con el suelo (Qi et al., 1994)	$\frac{(NIR - R)}{(NIR + R + L) * (1 + L)}$ Donde L es el componente de brillo del suelo con un valor de 0,5	$\frac{(b5-b4)}{(b5+b4+L)*(1+L)}$	$\frac{(b8-b4)}{(b8+b4+L)*(1+L)}$
NDWI	Índice de agua de diferencia normalizada (McFEETERS, 1996)	$\frac{(GREEN - NIR)}{(GREEN + NIR)}$	$\frac{(b3 - b5)}{(b3 + b5)}$	$\frac{(b3 - b8)}{(b3 + b8)}$
WDRI	Índice de vegetación de rango dinámico amplio (Gitelson, 2004)	$\frac{((0,05 * NIR) - R)}{((0,05 * NIR) + R)}$	$\frac{((0,05 * b5) - b4)}{((0,05 * b5) + b4)}$	$\frac{((0,05 * b8) - b4)}{((0,05 * b8) + b4)}$
EVI2	Índice de vegetación mejorado 2 (Jiang et al., 2008)	$\frac{2,5 * (NIR - R)}{(NIR + 2,4 * R + 1)}$	$\frac{2,5 * (b5 - b4)}{(b5 + 2,4 * b4 + 1)}$	$\frac{2,5 * (b8 - b4)}{(b8 + 2,4 * b4 + 1)}$
GNDVI	Índice de Vegetación de Diferencia Normalizada Verde (Wang et al., 2007)	$\frac{(NIR - GREEN)}{(NIR + GREEN)}$	$\frac{(b5 - b3)}{(b5 + b3)}$	$\frac{(b8 - b3)}{(b8 + b3)}$
NBRI	Índice de proporción de quema normalizada (Key & Benson, 2006)	$\frac{(NIR - SWIR)}{(NIR + SWIR)}$		$\frac{(b8 - b12)}{(b8 + b12)}$
GCI	Índice de clorofila verde (Gitelson et al., 2005)	$\frac{(NIR)}{(GREEN)} - 1$		$\frac{(b8)}{(b3)} - 1$
RED EDGE	Red Edge model (Gitelson et al., 2005)	$\frac{NIR}{Red\ edge\ 1 - 1}$		$\frac{b8}{b5 - 1}$

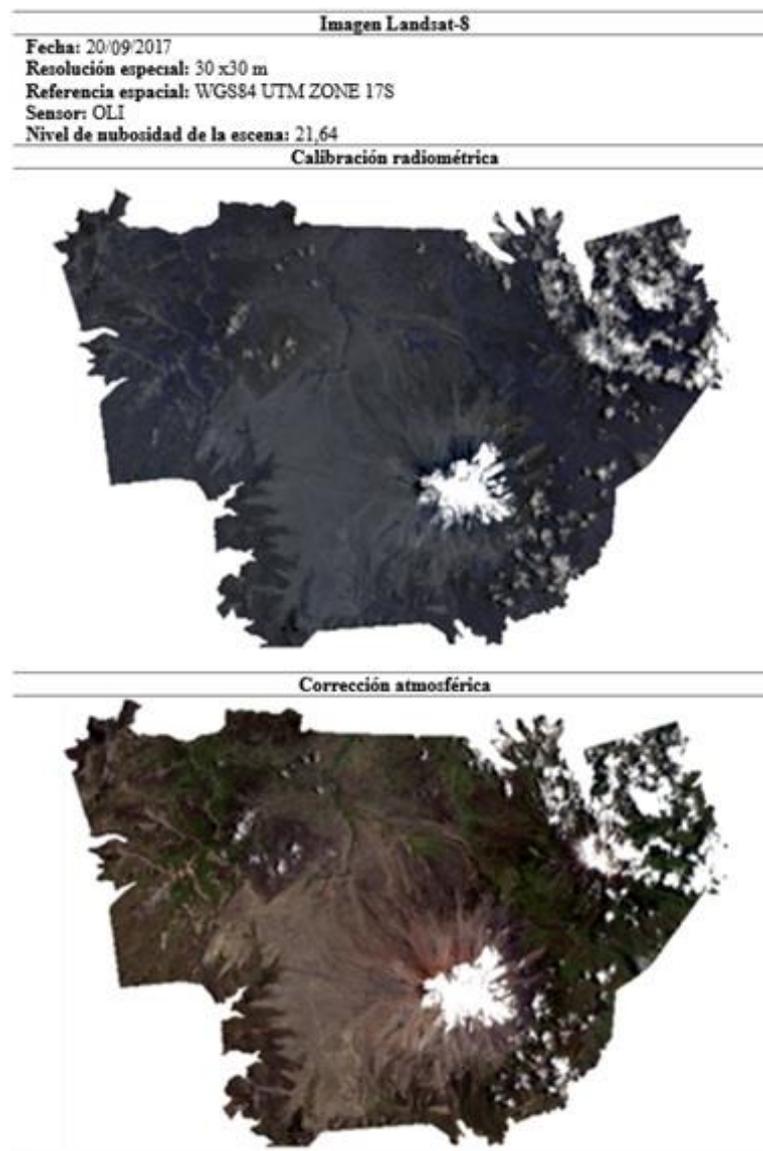


Figura 2.10: Procesamiento de la imagen Landsat-8 (Jara et al., 2019)

2. Instrumentación y medidas

2.3.2. Sentinel-2

La imagen Sentinel-2 (Figura 2.11) se obtuvo de Copernicus Open Access Hub (<https://scihub.copernicus.eu/>) de manera gratuita. Posee un nivel de procesamiento 1C que tiene correcciones radiométricas y geométricas, incluida la orto rectificación y registro espacial en un sistema de referencia global (ESA, 2015). El procesamiento de la imagen fue realizado con el software *SNAP 6.0*. Mediante el módulo de corrección atmosférica “Sen2Cor”, se llevó la imagen del nivel 1C al nivel 2A dando lugar a la imagen con sus valores de reflectividad bajo la atmósfera - BOA (ESA, 2021b). Usando la máscara de nubes del nivel 2A se las ha podido eliminar así como también a sus sombras.

Imagen Sentinel-2

Fecha: 2017-06-06 T15:42:17

Resolución espacial: 10 x 10m

Referencia espacial: WGS84 UTM ZONE 17S

Porcentaje de nubosidad de la escena: 30,15 %



Figura 2.11: Imagen Sentinel-2

La detección de cambios en el carbono del suelo pueden ocurrir en un período de 5 a 10 años (Conant & Paustian, 2002), por lo que se trabajó con la imagen Sentinel-2 del 06/06/2017, ya que el área de estudio presenta alta nubosidad durante todo el año y esta imagen fue la más cercana a la toma de muestras de biomasa de la vegetación y del carbono orgánico del suelo COS. A pesar de que la escena completa cuenta con un 30,15% de nubosidad total, el área de estudio se encuentra totalmente despejada lo que posibilita la detección de los peatlands.

A partir de la imagen Sentinel-2 se obtuvieron las variables biofísicas (Tabla 2.6): Leaf Area Index (LAI), fraction of Absorbed Photosynthetically Active Radiation (fAPAR), fraction of Vegetation Cover (fVC), Canopy Chlorophyll Content (CCC) y Canopy Water Content (CWC), como productos automáticos del software SNAP 6.0, a partir de una red neuronal (Weiss & Baret, 2016). Todas ellas son variables importantes en el monitoreo de la vegetación. LAI se define como la superficie de las hojas verdes de la vegetación, por unidad de área de suelo horizontal. fAPAR corresponde a la fracción de radiación fotosintéticamente activa absorbida por el dosel. fVC se define como la proyección vertical de las hojas de vegetación sobre la superficie del suelo, expresada como fracción o porcentaje del área de referencia. El CCC indica la cantidad de clorofila de la vegetación y es un muy buen indicador de estrés, incluidas las deficiencias de nitrógeno. El CWC se define como la cantidad de agua de la masa vegetal viva por unidad de superficie terrestre (g m^{-2}) (Weiss & Baret, 2016).

Tabla 2.6: Variables biofísicas de Sentinel-2 (Weiss & Baret, 2016)

Productos automáticos Sentinel-2 (variables biofísicas)	
LAI	Leaf Area Index
fAPAR	fraction of Absorbed Photosynthetically Active Radiation
fVC	fraction of Vegetation Cover
CCC	Canopy Chlorophyll Content
CWC	Canopy Water Content

Las imágenes Sentinel-2 contienen 13 bandas espectrales en las longitudes de onda visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR), con cuatro bandas a 10 m de resolución espacial, seis bandas a 20 m y tres bandas a 60 m, estas

2. Instrumentación y medidas

últimas para la corrección atmosférica Para los estudios de cobertura y uso de la tierra y la detección de cambios se pueden usar las 10 bandas de 10 y 20 m de resolución (Wang et al., 2016). En este trabajo, se calcularon también 8 índices de vegetación que se incluyen en la Tabla 2.5: NDVI, GNDVI, EVI2, SAVI, GCI, NBRI, NDWI y REDEDGE a partir de la imagen Sentinel-2. Estos productos fueron utilizados para mejorar los procesos de clasificación de los peatlands.

2.3.3. Sentinel-1

2.3.3.1. Características de la misión Sentinel-1

La misión Sentinel-1 está dentro de la constelación de satélites del Programa Copernicus, desarrollada por la Agencia Espacial Europea (ESA), comprende en la actualidad una constelación de dos satélites (Sentinel-1A y Sentinel-1B) en órbita polar, que operan día y noche y obtienen imágenes con un instrumento de radar de apertura sintética en la banda C, lo que les permite adquirir imágenes independientemente del clima y la nubosidad (ESA, 2021a).

Sentinel-1 proporciona datos para aplicaciones como monitoreo marítimo, monitoreo terrestre y gestión de emergencias, incluyendo seguimiento de la extensión y volumen del hielo marino principalmente en el Ártico, vigilancia del medio marino, vigilancia de derrames de hidrocarburos, detección de buques para la seguridad marítima, monitoreo de la superficie terrestre para detectar riesgos de terremotos o deslizamientos, monitoreo de bosques, inundaciones, áreas y tipos de cultivos, monitoreo para apoyar la ayuda humanitaria y situaciones de crisis (ESA, 2021a).

2.3.3.2. Modos de adquisición

Sentinel-1 opera en cuatro modos de adquisición exclusivos como se ve en la Figura 2.12: Stripmap (SM), Interferometric Wide Swath (IW), Extra-Wide Swath (EW) y Wave Mode (WV). El modo IW permite combinar un ancho de barrido (swath) de 250 km con una resolución espacial de 5 m por 20 m (single look). El modo IW

2. Instrumentación y medidas

es el modo de adquisición predeterminado en tierra. El modo EW se utiliza principalmente para el monitoreo costero de áreas extensas, incluido el tráfico de barcos, derrames de petróleo y monitoreo del hielo marino. El modo SM solo se utiliza para islas pequeñas y bajo pedido para eventos extraordinarios como la gestión de emergencias. Tener el modo IW como único modo operativo principal satisface la mayoría de los requisitos de servicio actuales, simplifica la planificación de la misión, disminuye los costos operativos y crea un archivo consistente a largo plazo (ESA, 2021a).

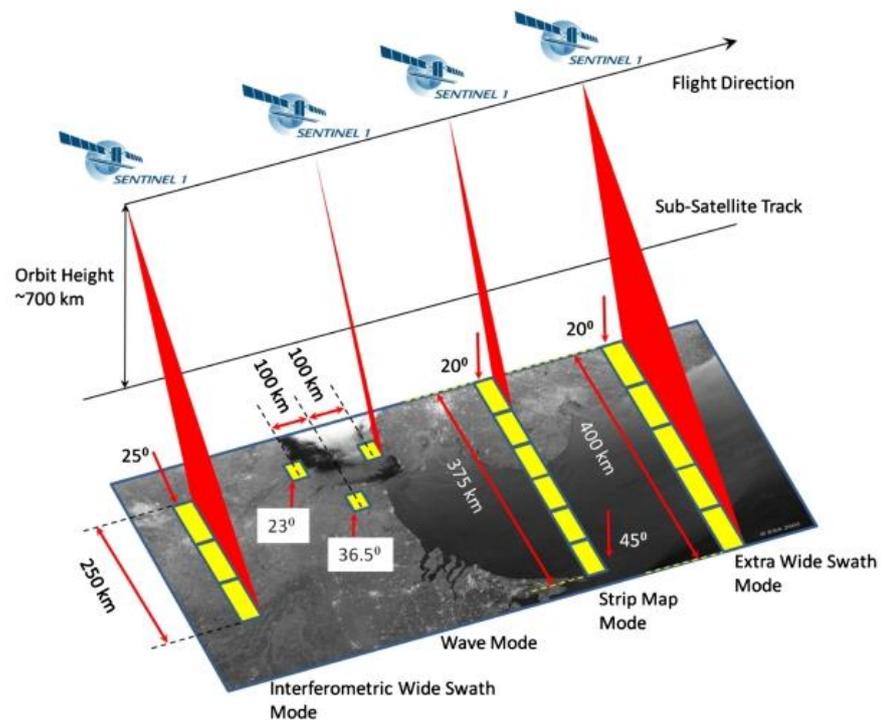


Figura 2.12: Modos de adquisición de datos de Sentinel-1 (ESA, 2021a)

2. Instrumentación y medidas

2.3.3.3. Polarización

Los canales de radar pueden transmitir o recibir en polarización horizontal o vertical: (Podest, 2021). Las mediciones de radar Sentinel-1 pueden ser:

- Canal HH: Transmitida Horizontalmente, Recibida Horizontalmente
- Canal HV: Transmitida Horizontalmente, Recibida Verticalmente
- Canal VH: Transmitida Verticalmente, Recibida Horizontalmente
- Canal VV: Transmitida Verticalmente, Recibida Verticalmente

Los instrumentos de SAR de banda C Sentinel-1 admiten el funcionamiento en polarización simple (HH o VV) como se muestra en la Figura 2.13 y polarización dual (HH + HV o VV + VH). Los productos SM, IW y EW están disponibles en polarización simple (HH o VV) o doble (HH + HV o VV + VH). WV es de polarización única (HH o VV). Los modos primarios de adquisición son IW, con polarización VV + VH sobre tierra, y WV, con polarización VV, sobre mar abierto (ESA, 2021a).

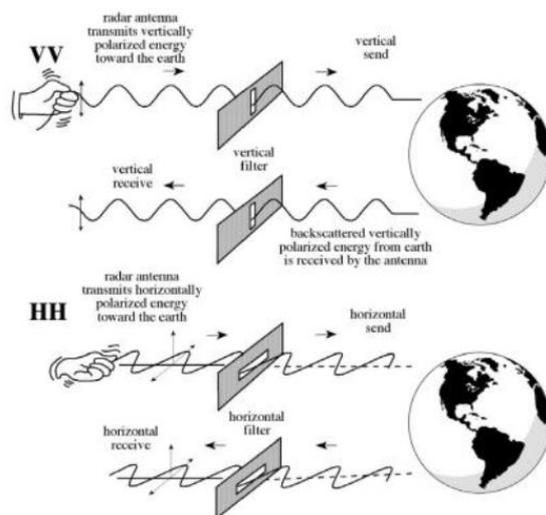


Figura 2.13: Fundamentos de la polarización (Podest, 2021).

2.3.3.4. Tipos de productos y niveles de procesamiento

Los productos de Sentinel-1 para cada modo de adquisición distribuidos por la ESA incluyen: datos sin procesar de nivel 0 (para uso específico), datos procesados de nivel 1 Single Look Complex (SLC) que comprenden imágenes complejas con amplitud y fase (distribución sistemática limitada a áreas relevantes específicas), datos de nivel 1 de Ground Range Detected (GRD) como intensidad de múltiples medidas y datos oceánicos de nivel 2 Ocean (OCN) para los parámetros geofísicos recuperados del océano, estos dos últimos con una distribuidos sistemática (ESA, 2021a). Los productos GRD nivel 1 consisten en datos SAR que se han detectado, promediado y proyectado al rango terrestre utilizando el modelo de elipsoide terrestre WGS84. La proyección elipsoide de los productos GRD se corrige utilizando la altura del terreno especificada en la anotación general del producto. La altura del terreno utilizada varía en la dirección azimut pero es constante en el rango (aunque puede ser diferente para cada sub-franja IW / EW) (ESA, 2021a).

2.3.3.5. Resolución

Los productos GRD de nivel 1 están disponibles en una de tres resoluciones espaciales: 1) Full Resolution (FR) para el modo SM, 2) High Resolution (HR) para los modos SM, IW y EW y 3) Medium Resolution (MR) para los modos SM, IW, EW y WV. Cada imagen en polarización VV y VH para los productos GRD de nivel 1 en HR en modo IW tiene una resolución espacial de 10*10 m (ESA, 2021a).

2.3.3.6. Revisita y cobertura

La constelación Sentinel-1 ofrece una mejora en el tiempo de revisita sobre ERS-1/2 y ENVISAT ASAR, y una continuidad de cobertura de amplias áreas con ENVISAT ASAR, pero logrando una resolución más alta y una cobertura de polarización dual potencialmente global sobre masas terrestres. Cada satélite Sentinel-1 está en una órbita casi polar, sincrónica con el Sol, con un ciclo de repetición de 12 días y 175 órbitas por ciclo. Tanto Sentinel-1 A como Sentinel-1 B comparten el mismo plano orbital con una diferencia de fase orbital de 180 °. Un solo satélite Sentinel-1 es potencialmente capaz de mapear las masas terrestres

2. Instrumentación y medidas

globales en el modo IW una vez cada 12 días, en una sola pasada (ascendente o descendente). La constelación de dos satélites ofrece un ciclo de repetición de 6 días en el ecuador. Dado que el espaciado de la trayectoria de la órbita varía con la latitud, el tiempo de revisita es significativamente menor en latitudes más altas que en el ecuador (ESA, 2021a).

2.3.3.7. Obtención de imágenes Sentinel-1

Se descargaron imágenes Sentinel-1, que abarcaban el área total de estudio como se muestra en la Figura 2.14, de Copernicus Open Access Hub (<https://scihub.copernicus.eu/>) de manera gratuita.

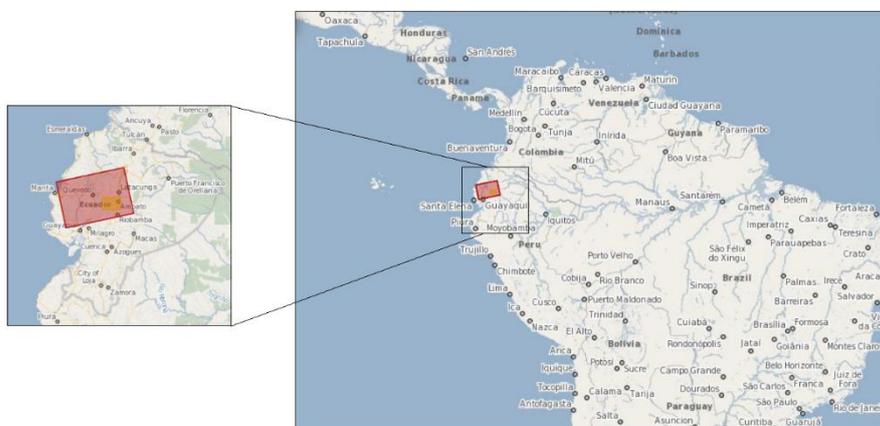


Figura 2.14: Footprint de Sentinel-1, en modo IW de nivel GDR, de la escena que contiene la RPFCH, en órbita ascendente 18

La búsqueda de las escenas se realizó en modo de adquisición IW y en nivel de procesamiento GDR en HR, disponibles en polarización dual (VV VH), entre los meses de noviembre del 2016 y febrero del 2017. El número de órbita seleccionado fue 18, el sentido de paso del satélite sobre la zona de estudio es ascendente y la hora de paso de Sentinel-1 sobre la RPFCH es alrededor de las 23:36 hora local. La Figura 2.15 muestra el resultado de la búsqueda de las escenas.

2. Instrumentación y medidas

The screenshot displays a search results page from Copernicus Open Access Hub. At the top, it indicates 'Display 1 to 5 of 5 products' and 'Order By: Ingestion Date'. A search request is shown: 'Request Done: (footprint:"Intersects(POLYGON((-79.18865953050185 -1.4990057501745184,-78.58184987892712 -1.4990057501745184,-78.58184987892712 -1.0797003254622837,-79.18865953050185 -1.0797003254622837,-79.18865953050185 -1.4990057501745184)))"'. Below this, five product entries are listed, each with a small satellite image thumbnail, a download URL, mission name (Sentinel-1), instrument (SAR-C), sensing date, and size (1.59 GB). The products are:

- S1B IW GRDH 1SDV_20170222T233602_20170222T233627_004419_007B0C_A374 (Sensing Date: 2017-02-22T23:36:02.881Z)
- S1B IW GRDH 1SDV_20170129T233603_20170129T233628_004069_007096_FD47 (Sensing Date: 2017-01-29T23:36:03.135Z)
- S1B IW GRDH 1SDV_20170105T233603_20170105T233628_003719_00663F_FE91 (Sensing Date: 2017-01-05T23:36:03.785Z)
- S1B IW GRDH 1SDV_20161212T233605_20161212T233630_003369_005C11_E363 (Sensing Date: 2016-12-12T23:36:05.749Z)
- S1B IW GRDH 1SDV_20161118T233606_20161118T233631_003019_005224_3A18 (Sensing Date: 2016-11-18T23:36:06.248Z)

Figura 2.15: Resultado de criterios de búsqueda en Copernicus Open Access Hub

Se obtuvieron cinco imágenes del satélite Sentinel-1B cada 24 días, que fueron descargadas para el análisis del COS y carbono de la vegetación como se muestra en la Tabla 2.7.

Tabla 2.7: Imágenes descargadas de Sentinel-1

SATÉLITE	MODO	NIVEL	FECHA	SENTIDO	ÓRBITA
S1-B	IW	GDR	18/11/2016	Ascendente	18
S1-B	IW	GDR	12/12/2016	Ascendente	18
S1-B	IW	GDR	05/01/2017	Ascendente	18
S1-B	IW	GDR	29/01/2017	Ascendente	18
S1-B	IW	GDR	22/02/2017	Ascendente	18

2. Instrumentación y medidas

2.3.3.8. Imagen original Sentinel-1

En la Figura 2.16 se muestra la imagen del 18 de noviembre del 2016 visualizada en el software *SNAP 6.0* antes de ser procesada. Se muestran las bandas de intensidad para VV y para VH en órbita 18 ascendente. La imagen original se muestra invertida.

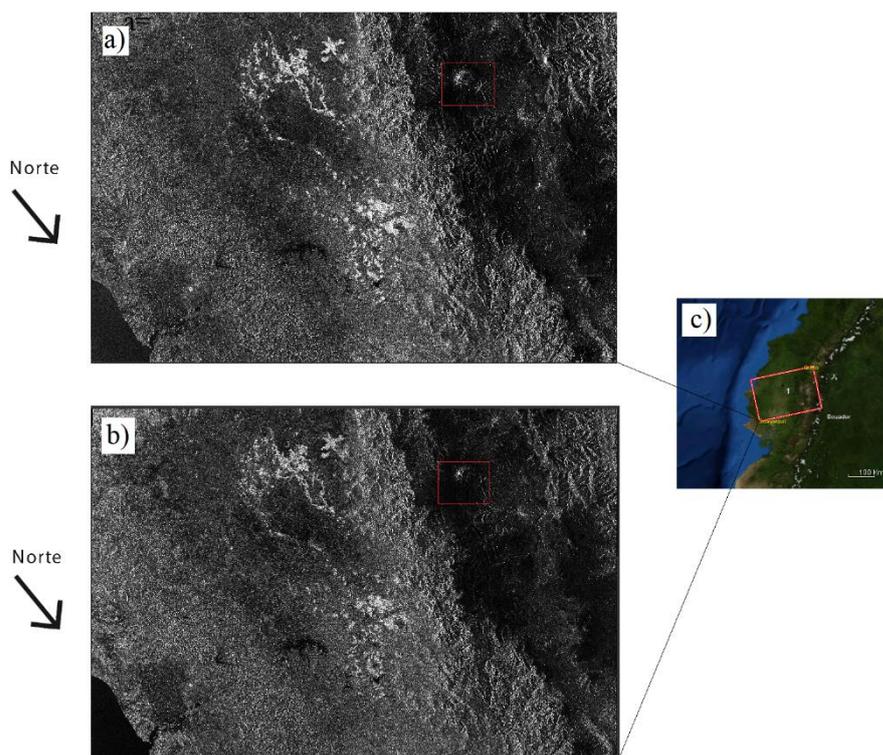


Figura 2.16: Imagen Sentinel-1 del 18/11/2016 sin procesar. a) *Intensity_VV*. b) *Intensity_VH*. c) *World View* del software *SNAP 6.0*

2.3.3.9. Pre procesamiento

El pre procesamiento ha sido aplicado de forma idéntica a todas las escenas utilizando la herramienta “Batch Processing” disponible en *SNAP*. Para construir la cadena de procesado que se ve en la Figura 2.17, primero se definió el proceso a aplicar y todos sus pasos en la herramienta “GraphBuilder” que muestra una plantilla del gráfico con dos operadores: “Read” (para leer los datos entrantes) y “Write” (para guardar los datos de salida). Se añadió el operador “Subset” para recortar la imagen. En cada ingreso de un operador se debe realizar la conexión entre operadores. En el siguiente paso, se actualizan los metadatos de la órbita con el operador “Apply-Orbit-File”. A continuación se elimina el ruido térmico con el operador “ThermalNoiseRemoval”. El ruido térmico en las imágenes SAR es la energía de fondo generada por el mismo receptor. Este ruido desvirtúa la reflectividad del radar haciendo que la señal tome valores más altos, afectando su precisión. Los productos Nivel-1 ofrecen una tabla de búsqueda de calibración de ruidos para cada conjunto de datos de medición, que puede ser utilizada para eliminar el ruido del producto. Se agregó el operador “Calibration” con la normalización *Sigma* para crear una imagen donde el valor de cada pixel esté relacionado directamente con la retro dispersión de la escena. Este proceso es esencial para hacer un análisis cuantitativo de la imagen. También es importante para poder comparar imágenes de diferentes sensores, diferentes modalidades, adquiridas en diferentes tiempos o procesadas por diferentes programas (Podest, 2021).

Las imágenes SAR tienen un efecto inherente de sal y pimienta llamado “speckle”, el cual degrada la calidad de la imagen, dificultando su interpretación. Para reducir este efecto y suavizar la imagen, se aplica un filtro *Lee Sigma* de speckle con el operador “Speckle-Filter”. Los datos aún se encuentran en geometría radar, además, por variaciones topográficas de una escena y la inclinación del sensor del satélite, las distancias pueden estar distorsionadas en las imágenes SAR. Por lo tanto, como último paso del pre procesamiento, se aplica una corrección al terreno, para compensar las distorsiones y re proyectar la escena a una proyección geográfica

2. Instrumentación y medidas

con el operador “Terrain-Correction”, el algoritmo utiliza el modelo de elevación digital SRTM para hacer la corrección (Podest, 2021).

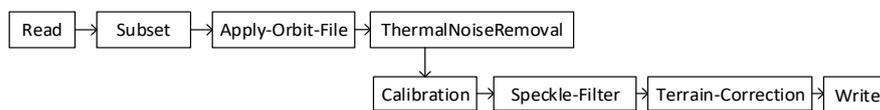


Figura 2.17: Cadena de procesamiento de imágenes Sentinel-1 en la herramienta “GraphBuilder” del software SNAP 6.0.

2.3.3.10. Imagen procesada de Sentinel-1

La Figura 2.18 muestra los resultados de aplicar la cadena de procesamiento implementada en SNAP, donde se puede observar que la imagen está en su orientación correcta, además del resultado del coeficiente de retrodispersión normalizado en dB para las dos polarizaciones VV y VH (Podest, 2021). Se ha generado la cadena de procesado para toda la serie temporal para ambas polarizaciones VV y VH.

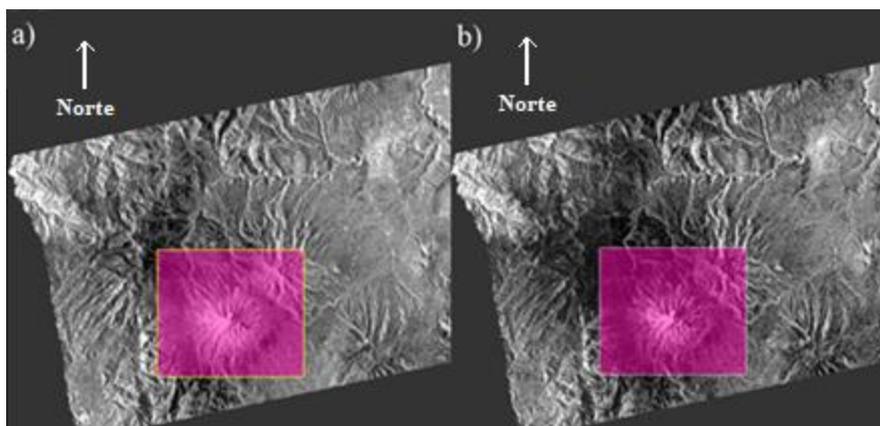


Figura 2.18: Imagen Sentinel-1 del 18/11/ 2016 procesada (Sistema de proyección UTM – WGS84 17S). a) VV_dB. b) VH_dB

2.3.3.11. Ratio VH/VV, VV/VH

Adicionalmente se calculan VV/VH y VH/VV en cada imagen, que se muestran en la Figura 2.19, así como su promedio, obteniendo un total de 22 productos a partir de las cinco imágenes radar (5 VV, 5 VH, 5 VV/VH, 5 VH/VV, 1 promedio de las cinco VV/VH y 1 promedio de las cinco VH/VV).

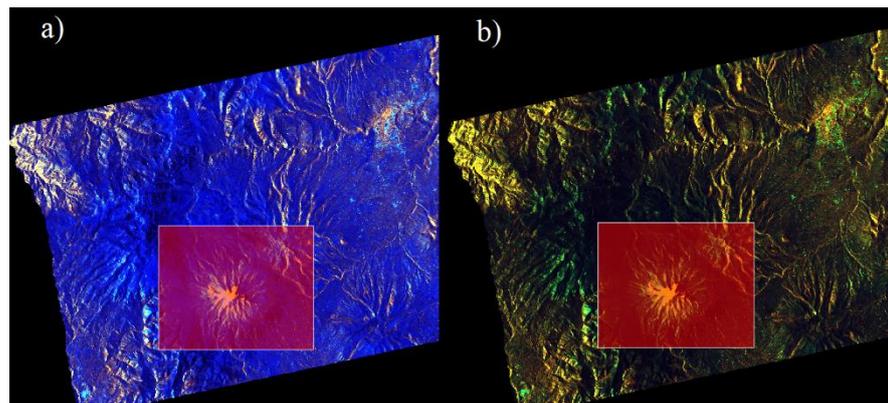


Figura 2.19: Composiciones RGB obtenidas de la imagen Sentinel-1 del 18/11/2016 procesada. a) Banda VV (canal rojo), VH (canal verde) y VV/VH (canal azul). b) Banda VV (canal rojo), VH (canal verde) y VH/VV (canal azul).

Estos 22 productos son exportados al software ArcGIS 10.4 para los siguientes procesos de preparación de datos de entrada usados en estimación del COS y del carbono de la vegetación. En la Figura 2.20 se muestran los productos de la polarización VV de la RPFCH de las cinco fechas descargadas.

2. Instrumentación y medidas

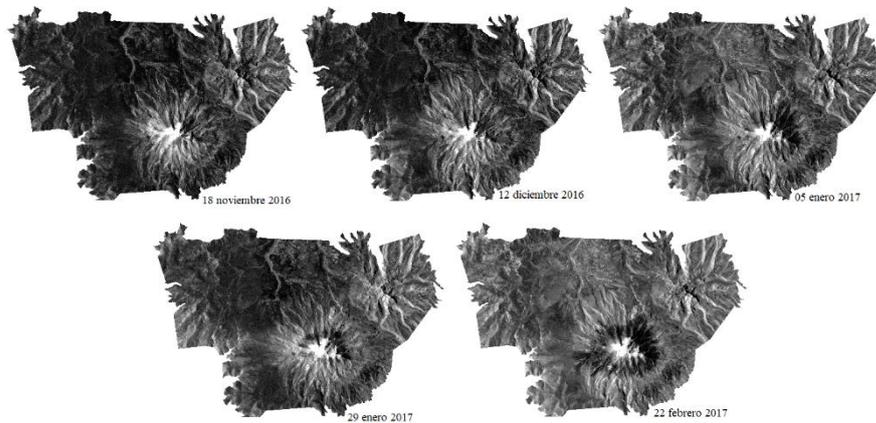


Figura 2.20: VV_dB de las cinco imágenes Sentinel-1 de la RPFCH

2.4. Datos topográficos

Los datos topográficos son uno de los predictores más utilizados para la estimación del contenido de COS (Rudiyanto et al., 2016; 2018; Wang et al., 2018; Zhou et al., 2020). A partir del modelo digital de elevación (DEM) de la RPFCH, descargado del Sistema Nacional de Información (SNI) del Ecuador (SNI, 2014) y mostrado en la Figura 2.21, se obtuvieron tres datos topográficos que fueron calculados con el software *ArcGIS 10.4*: (1) *Elevación*, obtenida con la herramienta *Extract Values to Point* de *Spatial Analyst Tools*, (2) *Pendiente*, con la herramienta *Slope* dentro de *Surface* en el *Spatial Analyst Tools* y (3) *Topographic Wetness Index (TWI)* con la herramienta *Wetness Index*. TWI fue desarrollado por Beven & Kirkby (1979), y se define como:

$$TWI = \ln \left(\frac{\alpha}{\tan \beta} \right) \quad (2.1)$$

Donde α es el área de captación específica (el área de pendiente ascendente acumulada que drena a través de una celda dividida por el ancho del contorno) y β

es la pendiente local. TWI es comúnmente utilizada para cuantificar el control topográfico en los procesos hidrológicos (Sørensen et al., 2006).

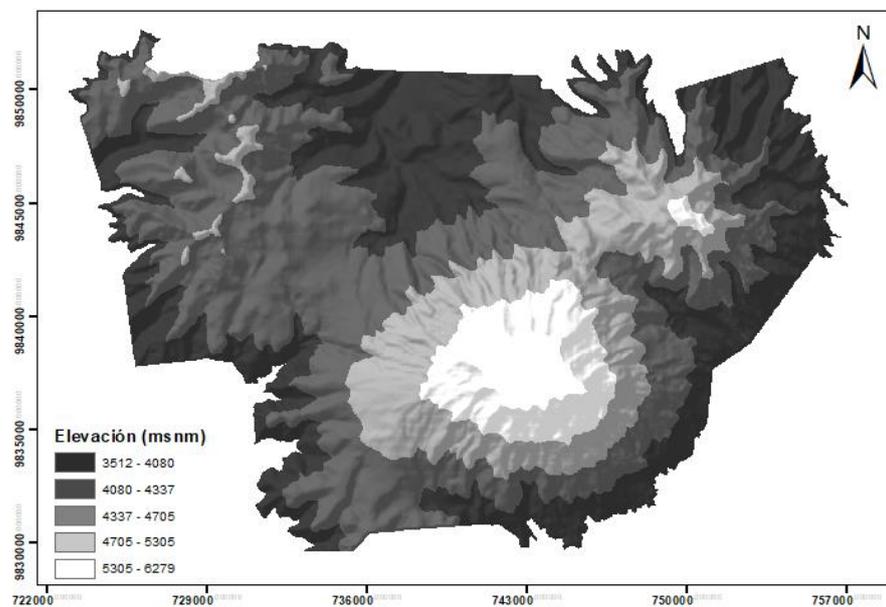


Figura 2.21: Modelo digital de elevación de la RPFCH (SNI, 2014)

2.5. Datos ambientales

Los datos ambientales usados en este trabajo y que se muestran en las Figuras 2.22 a 2.28 fueron: *ecosistema*, *usos* (usos de suelo), *taxonomía* del suelo, *textura*, *temperatura*, *precipitación* y *distancia a ríos*, obtenidas a partir de los archivos de información geográfica del SNI del Ecuador (SNI, 2014). *Ecosistema* contiene cuatro categorías: Gelidofitia, Nieve Perpetua, Paramo Herbaceo y Paramo Seco; *Usos* se divide en cuatro categorías: Cultivos de Ciclo Corto, Paisajes Minerales,

2. Instrumentación y medidas

Pastos y Vegetación Natural; *Taxonomía* con ocho categorías: Inceptisoles, Entisoles, Entisoles – Inceptisoles, agua, nieve, roca, sin_suelo y sin_definir; *Textura* contiene once categorías: Gruesa – moderada, Gruesa - muy fina, Moderadamente gruesa, Moderadamente gruesa - media, Moderadamente gruesa – muy fina, Media, agua, nieve, roca, sin_suelo y sin_información; *Precipitación* con cuatro rangos en mm: 500-750, 750-1000, 1000-1250 y 1250-1500; *Temperatura* separada en cinco rangos en °C: 0-2, 2-4, 4-6, 6-8 y 8-10, precipitación y temperatura contienen el valor de la media desde el año 2008 actualizado al 2014, que tienen como fuente al Instituto Nacional de Meteorología e Hidrología (INAMHI) en el SNI del Ecuador; y *distancia a ríos* calculado en *ArcGIS* con la herramienta del Arctoolbox *Spatial Analyst/Distance/Euclidian Distance*, a partir de la capa de información geográfica base RIO, del SNI de Ecuador.

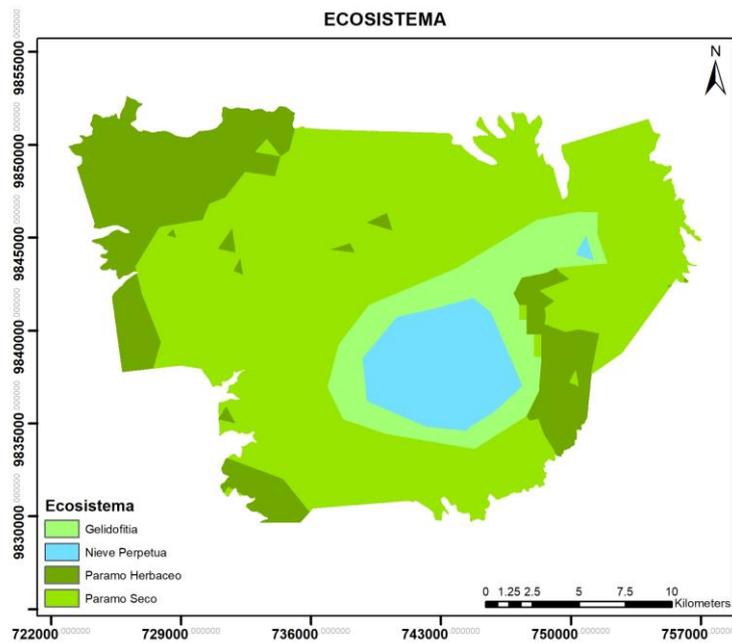


Figura 2.22: Capa Ecosistema de la RPFCH (SNI, 2014)

2. Instrumentación y medidas

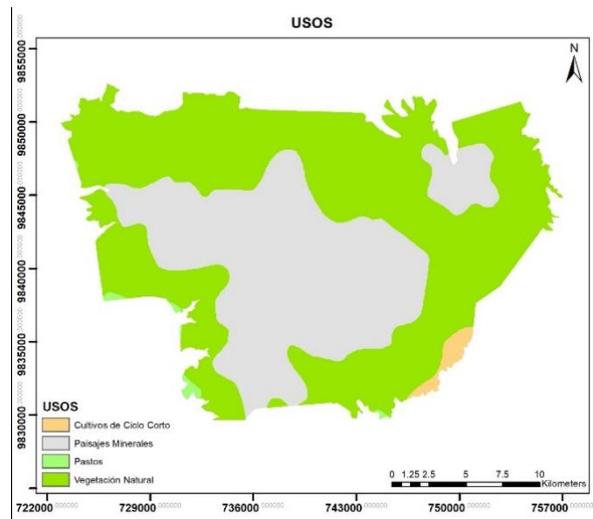


Figura 2.23: Capa Usos de la RPFCH (SNI, 2014)

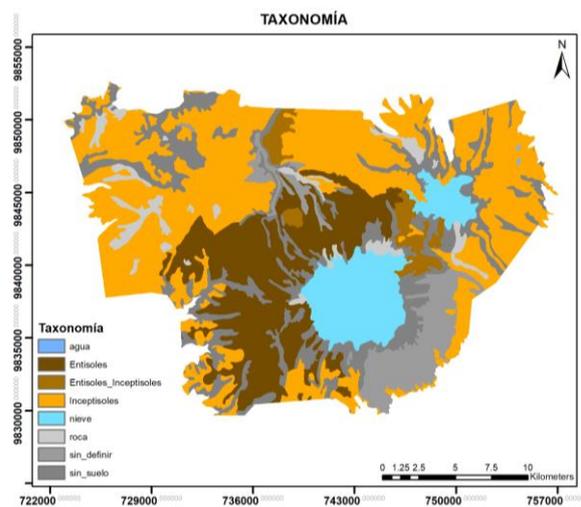


Figura 2.24: Capa Taxonomía de la RPFCH (SNI, 2014)

2. Instrumentación y medidas

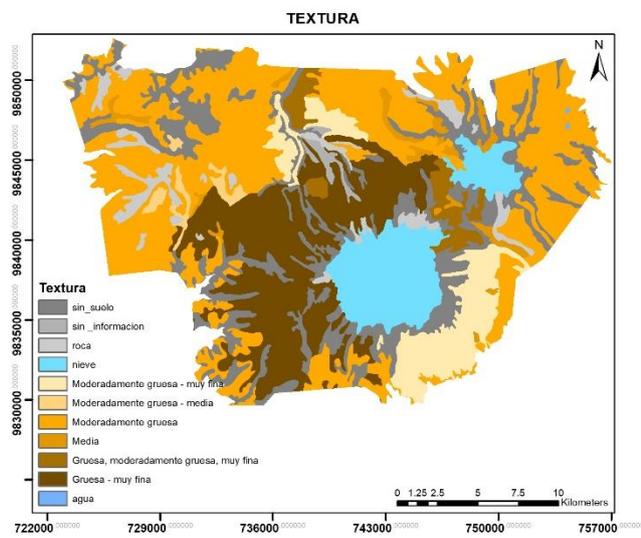


Figura 2.25: Capa Textura de la RPFCH (SNI, 2014)

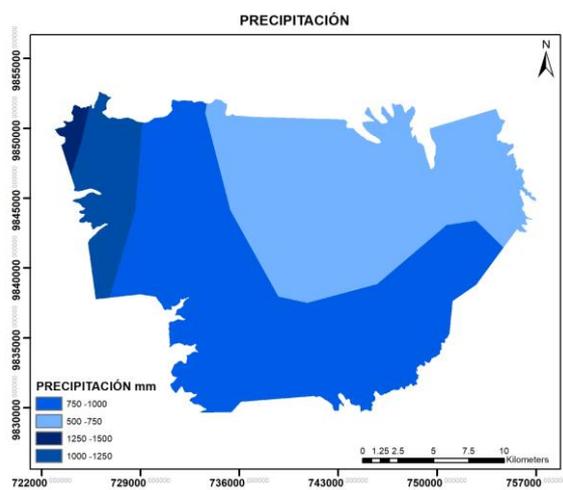


Figura 2.26: Capa Precipitación de la RPFCH (SNI, 2014)

2. Instrumentación y medidas

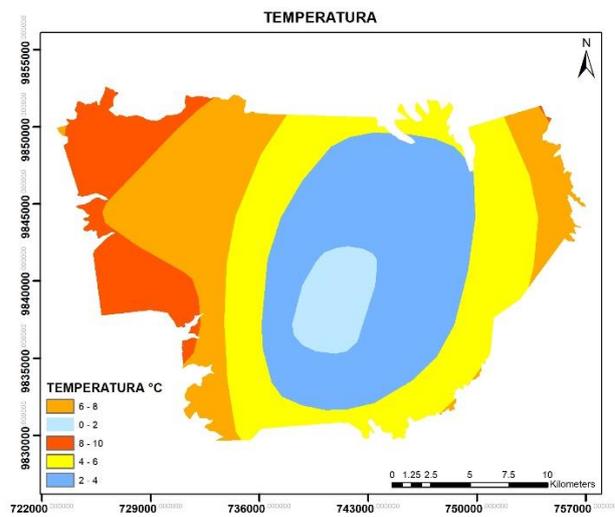


Figura 2.27: Capa Temperatura de la RPFCH (SNI, 2014)

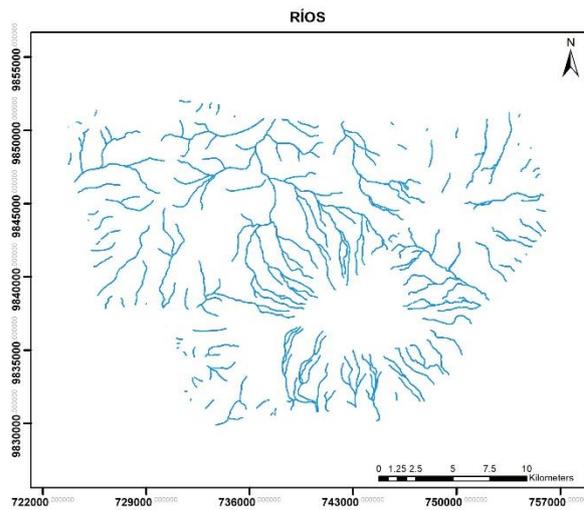


Figura 2.28: Capa Ríos de la RPFCH (SNI, 2014)

2.6. Variables para el cartografiado de los peatlands

Se han seleccionado un conjunto de variables para identificar y cartografiar los peatlands de la RPFCH, a partir de la comparación de las imágenes Landsat-8 y Sentinel-2 a través de índices espectrales de vegetación. Además, a partir de la imagen Sentinel-2 se utilizaron los productos automáticos de vegetación del software *SNAP 6.0*, el valor de las 10 bandas de la imagen y 8 índices espectrales de vegetación, como se muestra en la Tabla 2.8.

Tabla 2.8: Variables para el cartografiado

Comparación Landsat-Sentinel		Variables Biofísicas	Bandas	Índices espectrales
Landsat-8	Sentinel-2	Sentinel-2	Sentinel-2	Sentinel-2
NDVI SAVI NDWI WDRI EVI2	NDVI SAVI NDWI WDRI EVI2 REDEEDGE	LAI FAPAR FVC CCC CWC	Banda 2 – Blue Banda 3 – Green Banda 4 – Red Banda 5 – Red edge 1 Banda 6 – Red edge 2 Banda 7 – Red edge 3 Banda 8 – NIR 1 Banda 8A – NIR 2 Banda 11 – SWIR 1 Banda 12 – SWIR 2	NDVI GNDVI EVI2 SAVI GCI NBRI NDWI REDEEDGE

2.7. Variables para el contenido del carbono de la vegetación y el COS

El incremento de datos satelitales de libre acceso y la disponibilidad de algoritmos de aprendizaje automático en código abierto han mejorado la forma en que se puede

estudiar el suelo. Hay ventajas al utilizar esta información para generar eficientes y actualizados mapas digitales de suelos (Minasny et al., 2019). Ningún sensor puede medir todas las propiedades del suelo, por lo tanto, la integración de varios sensores en una única plataforma multisensor puede proporcionar beneficios operativos en comparación con los sistemas de un solo sensor (Viscarra et al., 2010).

En lugar de depender de una sola covariable, la combinación de imágenes ópticas y de radar produce mejores predicciones, y además, al añadir dimensiones multitemporales se ha demostrado que la información es eficaz para estudiar peatlands (Minasny et al., 2019). Los resultados de Torbick & Salas (2015) enfatizan la utilidad de la teledetección por satélite para la toma de decisiones sobre humedales y peatlands y su aplicación como herramienta rentable para respaldar el protocolo de monitoreo, reporte y verificación. La constelación Sentinel 1 y 2 es una poderosa herramienta para monitorear grandes ecosistemas ricos, complejos y sensibles que permite cartografiar los cambios en la cobertura de peatlands a lo largo del tiempo (Yesou et al., 2016).

Actualmente no se dispone de una buena estimación del almacenamiento potencial de carbono de los peatlands (Minasny et al., 2019). Por ello en este trabajo se han seleccionado una serie de variables topográficas, ambientales y de imágenes radar (Sentinel-1) y óptica (Sentinel-2) mostradas en la Tabla 2.9, para la estimación del carbono de la vegetación y el COS en el horizonte 0 a 30 cm.

2. Instrumentación y medidas

Tabla 2.9: Variables a utilizar para la estimación del carbono de la vegetación y el COS en el horizonte de 0 a 30 cm. Para VHN y VVN, N asume los valores del 1 al 5 que indican las fechas de la Tabla 2.7

TOPOGRÁFICAS	AMBIENTALES	IMAGEN ÓPTICA (SENTINEL-2)	IMÁGENES RADAR (SENTINEL-1)
Elevación	Ecosistema	Variables biofísicas	VH1
Pendiente (grados)	Usos	LAI	VH2
TWI (topographic wetness index)	Taxonomía	fAPAR	VH3
	Textura	fVC	VH4
	Temperatura	CCC	VH5
	Precipitación	CWC	VV1
	Distancia a ríos	Índices espectrales	VV2
		NDVI	VV3
		GNDVI	VV4
		EVI2	VV5
		SAVI	VH1/VV1
		GCI	VH2/VV2
		NBRI	VH3/VV3
		NDWI	VH4/VV4
		REDEGE	VH5/VV5
		Bandas	PROMEDIO(VH/VV)
		Banda 2 – Blue	VV1/VH1
		Banda 3 – Green	VV2/VH2
		Banda 4 – Red	VV3/VH3
		Banda 5 – Red edge 1	VV4/VH4
		Banda 6 – Red edge 2	VV5/VH5
		Banda 7 – Red edge 3	PROMEDIO(VV/VH)
		Banda 8 – NIR 1	
		Banda 8A – NIR 2	
		Banda 11 – SWIR 1	
		Banda 12 – SWIR 2	

Capítulo 3

Metodología

En el tercer capítulo se describe el método utilizado para determinar el mejor modelo de clasificación en la identificación de peatlands en la Reserva de Producción de Fauna Chimborazo. Se describen también los cuatro métodos utilizados para determinar el mejor modelo de regresión para la estimación del carbono de la vegetación y del carbono orgánico del suelo. Por otro lado, se detallan los modelos de clasificación y regresión propuestos en el presente estudio para el cartografiado y estimación del carbono respectivamente, así como los de validación para la evaluación de los resultados.

3. Metodología

3.1. Métodos de modelado

Para cartografiar los peatlands se usa como método de clasificación Random Forest Classification de Minitab®. Para la predicción de los valores del carbono de la vegetación y del COS se utilizan métodos del test de regresión MLRA del software con licencia gratuita ARTMO.

3.1.1. Random Forest Classification

La identificación y cartografiado de los peatlands del área de estudio se realizó usando Random Forest o bosque aleatorio (RF). Este es un poderoso clasificador de aprendizaje automático que consiste en la combinación de un conjunto de árboles de clasificación y regresión (CART) y establece etiquetas de clase. Las ventajas de RF incluyen: su naturaleza no paramétrica, alta precisión de clasificación y capacidad para determinar la importancia de las variables, así como también que RF es robusto ante la presencia de ruido (presencia de datos anómalos) (Ayala-Izurieta et al., 2021; Rodríguez-Galiano et al., 2012). Los bosques aleatorios son una combinación de predictores de árboles, cada árbol depende de los valores de un vector aleatorio muestreado independientemente y con la misma distribución para todos los árboles del bosque. La generalización del error de un bosque de clasificadores de árboles depende de la fuerza de los árboles individuales en el bosque y de la correlación entre ellos (Breiman, 2001). El clasificador de RF necesita principalmente la definición de dos parámetros para generar un modelo de predicción: el número de árboles de clasificación deseado y el número de variables de predicción utilizadas en cada nodo para hacer crecer el árbol (Rodríguez-Galiano et al., 2012). Las estimaciones internas también se utilizan para medir la importancia de las variables. Los bosques aleatorios son una herramienta eficaz de predicción, las entradas y características aleatorias producen buenos resultados en la clasificación (Breiman, 2001). El modelo matemático de RF es el siguiente:

3. Metodología

$$\{h(x, \theta_k), k = 1, 2 \dots i \dots\} \quad (3.1)$$

donde h representa el clasificador de RF, x es la variable de entrada y $\{\theta_k\}$ representa los vectores aleatorios distribuidos de forma idéntica e independiente que se emplean para producir cada árbol CART (Liu et al., 2016). A partir del conjunto de datos de entrenamiento, compuesto por la variable dependiente (Y) que en el presente estudio está representada por la categoría peatland y los predictores ($X_1, X_2, \dots X_n$), que para el presente estudio son las variables topográficas, ambientales, ópticas y de radar, se forma el vector aleatorio Y, X, con el que se genera un árbol que empieza con un nodo de inicio. Los nodos son la base de construcción de los árboles y pueden tener ramificaciones conocidas como particiones, si el nodo no tiene ramificaciones se los denomina como terminal (Ayala-Izurieta et al., 2021). El árbol CART individual, es el clasificador base de RF y, por lo tanto, la creación de cada árbol CART tiene un efecto significativo en la clasificación mediante RF. Para mejorar la generalización de RF, se selecciona dos tercios de las muestras de entrenamiento para generar cada árbol CART. El tercio restante de las muestras de entrenamiento, llamadas datos fuera de la bolsa (OOB), son utilizados para realizar una validación cruzada interna, que tiene como objetivo medir la precisión de la clasificación de RF (Liu et al., 2016).

Los procesos del clasificador RF, como se muestran en la Figura 3.1, son: en la sección A, el *proceso de entrenamiento*, en donde cada árbol de decisión del conjunto está basado en una muestra de arranque aleatoria de los datos originales, contiene ejemplos positivos (etiquetas verdes) y negativos (etiquetas rojas). En la sección B, el *proceso de clasificación*, en el que la predicción de clases para nuevas instancias utilizando un modelo de bosque aleatorio se basa en un procedimiento de votación por mayoría entre todos los árboles individuales. El procedimiento para cada árbol es el siguiente: para cada nuevo punto de datos, el algoritmo comienza en el nodo raíz de un árbol de decisión y recorre el árbol (ramas resaltadas) probando los valores de las variables en cada una de las divisiones (nodos rosa pálido), según cada uno selecciona la siguiente rama a seguir. Este proceso se repite hasta que se alcanza un nodo hoja, que asigna una clase a esta instancia: los nodos verdes predicen para la clase positiva, los nodos rojos predicen para la clase

negativa. Al final del proceso, cada árbol emite un voto por la etiqueta de clase preferida y el voto mayoritario se elige como predicción final (Liu et al., 2017; Machado et al., 2015).

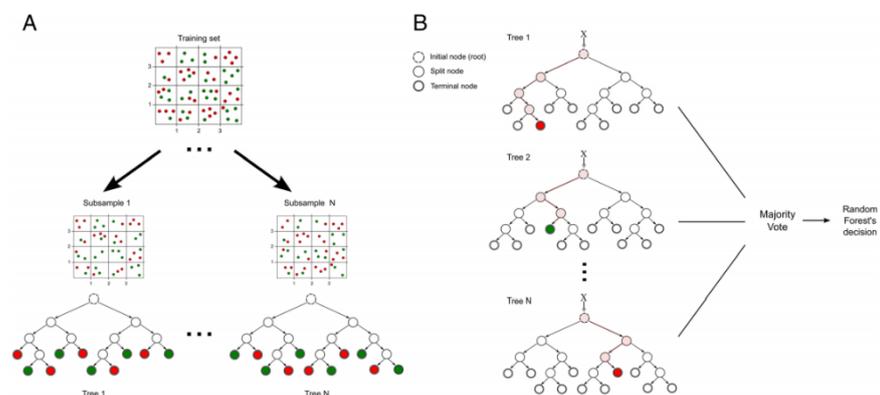


Figura 3.1: Procesos de RF, A) Proceso de entrenamiento, B) Proceso de clasificación (Liu et al., 2017; Machado et al., 2015)

RF generalmente usa el índice de Gini como medida de heterogeneidad, para determinar las condiciones de división para cada nodo en el árbol CART, que mide la impureza de un elemento dado con respecto al resto de las clases (Breiman, 2001; Liu et al., 2016). RF también puede calcular la proximidad entre dos muestras de la misma clase y cuenta el número de veces que dichas muestras aparecen en el mismo nodo terminal (es decir, cuántos árboles etiquetan cada posible par de casos de la misma clase con la misma regla de división). Una vez que se ha construido cada árbol y se calculan las proximidades para cada par de casos, se normalizan dividiendo por el número de árboles. Las proximidades son susceptibles de ser utilizadas para reemplazar datos faltantes y localizar valores atípicos (es decir, sitios mal etiquetados en conjuntos de entrenamiento) (Rodríguez-Galiano et al., 2012).

Cabe indicar que en diferentes estudios en peatlands, las precisiones más altas se han logrado con la aplicación de RF, así por ejemplo en clasificaciones de tipos de

3. Metodología

suelo para peatlands (Pittman et al., 2021) y clasificación de cobertura terrestre (Nitze et al., 2015), también se ha utilizado en clasificación de peatlands (Millard & Richardson, 2015) y cobertura terrestre dentro de peatlands (White et al., 2017).

3.1.2. Test de regresión (MLRA)

Los modelos de Transferencia Radiativa (RT) se han convertido en herramientas importantes para el análisis de datos ópticos de observación de la Tierra, proporcionando vínculos significativos entre la reflectancia y las aplicaciones ambientales. *El operador de modelos de transferencia radiativa automatizada (ARTMO)* es un paquete de software que, entre otras cosas, proporciona todas las herramientas necesarias para ejecutar e invertir un conjunto de modelos RT (Verrelst & Rivera, 2018a). ARTMO permite evaluar y aplicar un conjunto de MLRA's no lineales y no paramétricos basados en funciones kernel, que requieren de una fase de aprendizaje basada en datos de entrenamiento. Así también se pueden cuantificar las similitudes con muestras de entrada y obteniendo información relevante para mapear las propiedades de la superficie.

La estimación del carbono de la vegetación y del COS se realizó mediante la calibración de modelos de regresión a través del test de regresión MLRA en ARTMO. Los algoritmos MLRA's permiten determinar el grado de correlación entre las variables (Caballero, 2018) mencionadas en el capítulo anterior, es decir carbono de la vegetación y COS. Los datos de entrenamiento provienen de 320 mediciones de campo tanto para el carbono de la vegetación como para el COS. Los métodos de modelado MLRA que se aplicaron son: Gaussian Processes Regression (GPR), Variational Heteroscedastic Gaussian Processes Regression (VHGPR), Random Forest (TreeBagger) y Kernel ridge Regression (KKR).

3.1.2.1. Gaussian Processes Regression (GPR)

El proceso gaussiano (GP) hace posible describir una distribución sobre funciones. En sí, un GP es una colección de variables aleatorias, cualquier número finito de las cuales se tiene una distribución gaussiana conjunta. La Figura 3.2, indica de manera gráfica como trabaja el modelo GPR. Los cuadrados representan variables observadas y los círculos representan incógnitas. La barra horizontal gruesa representa un conjunto de nodos completamente conectados. Una observación y_i es condicionalmente independiente de todos los demás nodos dada la correspondiente variable latente, f_i . Debido a la propiedad de marginación de los GP, la adición de entradas adicionales, x , variables latentes, f , y objetivos no observados, y^* , no cambia la distribución de ninguna otra variable (Rasmussen & Williams, 2006). Un proceso gaussiano es una generalización de la distribución de probabilidad gaussiana, se considera que cualquier set de observaciones D posee una distribución normal multi variante, de esta manera se pueden describir las características de las observaciones en su totalidad ya sea por su vector medio μ o función media $\mu(x)$ y la matriz de covarianza Σ o función de covarianza $\Sigma(x, x)$.

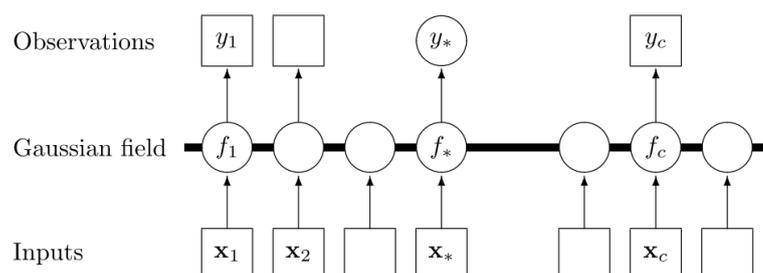


Figura 3.2: Proceso del modelo GPR

La relación funcional entre una entrada y la variable objetivo de salida puede enfrentarse a un problema de sobreajuste, esto se debe a que pueden encontrarse una gran cantidad de funciones que se ajustan a los datos. La solución es restringir la capacidad del modelo ya sea mediante una imposición de conocimiento previo o

3. Metodología

esquemas que conlleven a soluciones simples. Las funciones kernel han sido utilizadas como una opción porque se ocupan de manera eficiente con conjuntos de datos de bajo tamaño de dimensionalidad potencialmente alta, como es el caso de predicciones de parámetros de imágenes multiespectrales o hiperespectrales utilizando modelos entrenados por datos de mediciones de campo; también debido a que las funciones kernel no asumen una distribución de datos previa explícita, sino que son modelos inherentemente no paramétricos (Verrelst et al., 2013).

Sin embargo, dado que el objetivo es tener un modelo no solo con elevada precisión, si no también obtener intervalos de confianza en las predicciones, el modelado bayesiano no paramétrico como es el caso de GPR, constituye un método adecuado para abordar el problema de la recuperación de los parámetros fisicoquímicos del suelo (como el COS) y del carbono de la vegetación con aplicaciones de teledetección (Rasmussen & Williams, 2006; Verrelst et al., 2013). Los GPR pueden proporcionar predicciones a nivel del pixel con intervalos de confianza y se ha evidenciado también su adaptabilidad con los datos incluso en presencia de ruido (Camps-Valls et al., 2009; Verrelst et al., 2013). GPR ha podido superar los resultados obtenidos en la evaluación de parámetros biofísicos usando otros métodos de regresión no paramétricos tales como Neural Network Regression (NN) y Kernel Ridge Regression (KRR) (Verrelst et al., 2012).

GPR es un método de modelado de regresión no lineal y no paramétrico, en el cual se considera la varianza del set de datos y una maximización del margen de probabilidad en el set de entrenamiento usando una función kernel Gaussiana anisótropa escalada (Pérez-Planells et al., 2015).

Se usó GPR para obtener el carbono de la vegetación y el COS usando como datos de entrada los datos espectrales y productos biofísicos de Sentinel-2, datos de Sentinel-1, así como también datos ambientales y su relación con las observaciones correspondientes a las campañas de mediciones de campo. GPR permite conocer características relevantes de las variables de entrada (bandas) (Rasmussen & Williams, 2006). También es posible evaluar la contribución relativa destacando

las más relevantes para el modelo de predicción, lo cual resulta muy útil a la hora de optimizar el modelo y desvelar el aporte de cada una de las entradas en la predicción del parámetro de estudio.

La relación entre los datos de entrada (x) y la variable de salida (\hat{y}) se da de la siguiente manera:

$$\hat{y} = f(x) = \sum_{i=1}^N \alpha_i K(x_i, x) \quad (3.3)$$

Donde:

$(x)_{i=1}^N$: corresponden a las bandas de entrada usadas en el entrenamiento.

α_i : son los pesos asignados a las bandas de entrenamiento

K : es una función de núcleo sofisticada que evalúa la similitud entre el espectro de prueba y todas las N bandas o variables de entrenamiento (Camps-Valls et al., 2009; Verrelst et al., 2013; Verrelst et al., 2012).

La función de kernel gaussiana anisótropa escalada se expresa de la siguiente manera:

$$K_{(x_i, x_j)} = v \exp\left(-\sum_{b=1}^B \frac{(x_i^b - x_j^b)^2}{2\sigma_b^2}\right) \quad (3.4)$$

Donde:

v : factor de escala

B : número de variables (bandas)

σ_b : factor que controla la propagación de la relación para cada una de las variables de entrada b (Van Wittenberghe et al., 2014; Verrelst et al., 2013).

Los parámetros v , σ_b y α_i son optimizados de manera automática aplicando marginal likelihood en el set de entrenamiento (Camps-Valls et al., 2009; Rasmussen & Williams, 2006; Van Wittenberghe et al., 2014). Como resultado de la optimización se tienen valores de α_i que indican la relevancia de cada banda de entrada x_i . La predicción media viene a constituir el promedio ponderado de los

3. Metodología

valores de los parámetros de interés (COS y el carbono de la vegetación) asociados a las muestras de entrenamiento más cercanas a la muestra de prueba o análisis. La inversa de σ_b representa la relevancia de cada banda b , con lo cual se tiene que valores bajos de dicho parámetro indican que determinada banda b aporta mayor información para la función de entrenamiento K (Verrelst et al., 2013). La relevancia de las bandas puede ser representada en ARTMO a través de polar plots, que obtienen una representación positiva de la relevancia espectral, con una conversión de valores menores de σ_b en valores mayores y el relativo σ_b . Los polar plots también introducen una función de escala para detectar diferencias de relevancia entre bandas, esto se define en la expresión (3.5) y para la representación gráfica se utiliza la expresión (3.6) (Peppo et al., 2021).

$$\sigma^2 = \left(1 - \left(\frac{\sigma^2}{\max \sigma^2} \right) / (\text{sum} \sigma^2) \right) * 100 \quad (3.5)$$

$$\sigma^2 = \log_{10} \left(\frac{\sigma^2}{\max \sigma^2} \right) + 1 \quad (3.6)$$

La evaluación y predicción de COS y el carbono de la vegetación con GPR es realizada en la versión 3.29 del software *ARTMO* (Verrelst & Rivera, 2021), con el paquete de herramientas correspondientes al módulo de algoritmos de regresión de aprendizaje automático (MLRA). Se destina 70% de las bases de datos (carbono de la vegetación y COS) para el entrenamiento del modelo y el 30 % restante se utiliza para la validación.

3.1.2.2. Variational Heteroscedastic Gaussian Processes Regression (VHGPR)

Los procesos gaussianos estándar (GP) modelan el ruido de las observaciones como constante en todo el espacio de entrada. Esta es a menudo una suposición demasiado restrictiva, pero necesaria para que la inferencia de GP sea manejable (Lázaro-Gredilla & Titsias, 2011). Para hacer frente a la variación de ruido dependiente de

la entrada, los GP heterocedásticos permiten que la potencia del ruido varíe suavemente a lo largo del espacio de entrada (Estévez et al., 2020). Se entrenó un algoritmo de VHGPR con simulaciones generadas para la estimación del carbono de la vegetación y el COS en el horizonte de 0 a 30 cm.

VHGPR se ha utilizado además para el cartografiado de LAI debido a que ofrece precisiones superiores y menos incertidumbres (Estévez et al., 2020) y ha mostrado ser una excelente alternativa al GPR estándar en varios ejemplos relevantes de observación de la Tierra: la estimación de clorofila de la vegetación a partir de imágenes hiperespectrales y la estimación de la concentración de clorofila oceánica a partir de reflectancias medidas in situ (Lázaro-Gredilla et al., 2014) y en el monitoreo de las características bioquímicas y biofísicas de cultivos en áreas agrícolas, basados en productos de datos Copernicus de Sentinel-2 (Estévez et al., 2021).

3.1.2.3. Random Forest (TreeBagger)

El empaquetado de predictores es un método para generar múltiples versiones de un predictor y usarlas para obtener un predictor agregado. La agregación promedia sobre las versiones al predecir un resultado numérico. Las múltiples versiones se forman haciendo réplicas de arranque del conjunto de aprendizaje y usándolas como nuevos conjuntos de aprendizaje. Las pruebas en conjuntos de datos reales y simulados que utilizan árboles de regresión muestran que el empaquetado puede proporcionar ganancias sustanciales en la precisión (Breiman, 1996; 2001). Random Forest (Tree Bagger) combina el enfoque de empaquetado con el de bosque aleatorio de agregación de múltiples árboles de decisión (Abdelbaki et al., 2020).

Random Forest (TreeBagger) como método de modelado de regresión no lineal no paramétrica, ha resultado mejor para estimaciones de variables biofísicas, como el contenido de clorofila del dosel (Abdelbaki et al., 2020) y el contenido de clorofila de la hoja (Upreti et al., 2019).

3. Metodología

3.1.2.4. Kernel ridge Regression

KRR como método de modelado de regresión no lineal no paramétrica, minimiza los residuos del ajuste de mínimos cuadrados ampliando las dimensiones de las características del espacio. Se le considera como una aproximación a la versión kernel del método de regresión lineal (Pérez-Planells et al., 2015).

KRR produce altas precisiones para cartografiar tipos de superficies urbanas complejas (Verrelst et al., 2020) y para estimaciones del contenido de nitrógeno en la superficie (Okujeni et al., 2014).

3.2. Entrenamiento de los modelos de clasificación y regresión propuestos

3.2.1. Modelos de clasificación propuestos

A las variables para el cartografiado mostradas en la Tabla 2.8, se las va a agrupar y definir como modelos de clasificación (MC), como se muestra en la Figura 3.4. Se propone como MC1 a la comparación de las imágenes Landsat-8 y Sentinel-2 mediante índices de vegetación. Además a partir de la imagen Sentinel-2 se propone como MC2 a las variables biofísicas, como MC3 a las 10 bandas, como MC4 a 8 índices de vegetación y como MC5 a la combinación de las variables de los modelos de clasificación 2, 3, 4.

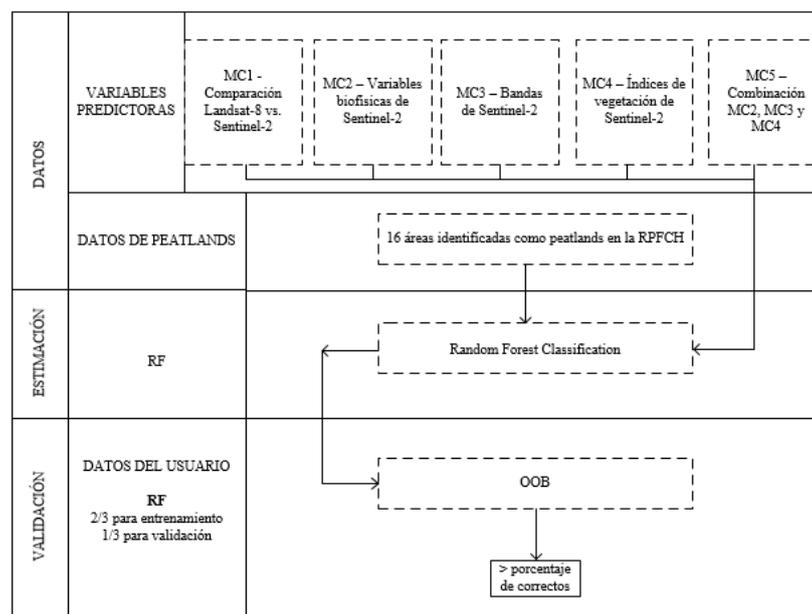


Figura 3.4: Diagrama de la clasificación de peatlands, a partir de los 5 modelos de clasificación (MC) propuestos

3.2.2. Calibración de los modelos de clasificación propuestos

Para cada uno de los cinco modelos se utilizó el clasificador RF. Para MC1, se extrajo el archivo en formato ráster de las zonas de muestreo de Landsat-8 y Sentinel-2 con la información de los índices de vegetación. Este ráster se transformó a archivo vectorial (shapefile) georreferenciado con el valor calculado de cada uno de los índices, además de una variable denominada USO, a la que se le asignó valores en una escala del 1 al 4 de acuerdo a las siguientes categorías: peatland, que incluye tres niveles: peatland intervenido [1], medianamente conservado [2] y conservado [3] y el resto a la categoría Otros [4]. Esto se hizo para

3. Metodología

establecer el sensor con mayor sensibilidad en la identificación de peatlands. Una vez determinado el mejor satélite (Landsat-8 o Sentinel-2) se lo usó para identificar con mayor exactitud el área ocupada por peatlands. Para los modelos de clasificación MC2, MC3, MC4 y MC5, solo se usa 2 categorías: [1] Peatland y [0] Otros, puesto que para la estimación del carbono de la vegetación y del COS, era necesario únicamente el área de los peatlands en nuestro estudio por lo que no se tomó en cuenta el estado de conservación. Se calibró el algoritmo de autoaprendizaje a partir del archivo de entrenamiento en formato .csv, se configuró el “target” que hace referencia al valor conocido que sería USO, también el “predictor” que corresponde a las variables de los modelos que fueron analizadas por su capacidad para la clasificación, ya que nuestro objetivo es identificar que es peatland y que no. Como resultado de la calibración del algoritmo se obtiene un archivo con extensión .grv, este archivo denominado grove es utilizado para la clasificación, se lo aplica al total de puntos de la RPFCH con las mismas variables utilizadas para la calibración a través del procedimiento denominado score. La manera de realizar el score es introduciendo un archivo alfanumérico que contiene todas las variables predictivas excepto la variable USO ya que ésta es la variable que será predicha. Como resultado se obtiene un archivo alfanumérico que contiene el valor de USO permitiendo clasificar a los peatlands y cartografiarlos con el modelo de clasificación que obtiene el mayor porcentaje global de correctos.

3.2.3. Validación de los modelos de clasificación propuestos

Para medir la precisión de los modelos de clasificación en RF se realiza una validación cruzada interna, con el porcentaje de correctos a partir del subconjunto de datos OOB que son el tercio restante de las muestras del entrenamiento (Liu et al., 2016). La proporción de clasificaciones erróneas sobre todos los elementos OOB se denomina error fuera de la bolsa (Peters et al., 2007). El error OOB es una estimación insesgada del error de generalización. Los bosques aleatorios producen un valor límite del error de generalización. A medida que aumenta el número de árboles, el error de generalización siempre converge. El número de árboles debe establecerse lo suficientemente alto para permitir esta convergencia. En consecuencia, los bosques aleatorios no se sobre ajustan. Un límite superior del

error de generalización se puede derivar en términos de dos parámetros que miden cuán precisos son los árboles de clasificación individuales y cuán diversos son los árboles de clasificación diferentes: (i) la fuerza de cada árbol individual en el bosque; y (ii) la correlación entre dos árboles cualesquiera en el bosque (Breiman, 2001; Peters et al., 2007). Un árbol de clasificación con un error bajo es un clasificador fuerte. La fuerza y la correlación no son parámetros definidos por el usuario. Sin embargo, la reducción del número de variables predictivas seleccionadas al azar para dividir los nodos disminuye tanto la fuerza como la correlación. Disminuir la fuerza de los árboles individuales aumenta el error del bosque. Mientras que disminuir la correlación disminuye el error del bosque. El método de bosque aleatorio estima la importancia de una variable predictiva al observar cuánto aumenta el error de OOB cuando los datos de OOB para esa variable se permutan mientras que todas las demás variables permanecen sin cambios. El aumento del error OOB es proporcional a la importancia de la variable predictiva. Otra medida evalúa la proximidad de diferentes puntos de datos entre sí. Se genera una matriz de proximidad $N \times N$ (con N el número de puntos de datos), donde cada elemento representa la fracción de árboles en la que los dos puntos de datos correspondientes caen en el mismo nodo terminal. La intuición es que los puntos de datos similares deberían estar en el mismo nodo terminal con más frecuencia que los diferentes (Peters et al., 2007).

3.2.4. Modelos de regresión propuestos

A las variables mostradas en la Tabla 2.9 para la predicción del carbono de la vegetación y del COS, las vamos a agrupar y definir en este estudio como modelos de regresión (MR). Se propone como MR1 a las variables topográficas, como MR2 a las ambientales, como MR3 a las ópticas (Sentinel-2), como MR4 a las radar (Sentinel-1) y como MR5 a la mejor combinación de las variables de los modelos de regresión 1, 2, 3 y 4 propuestos, como se muestra en la Figura 3.5.

3. Metodología

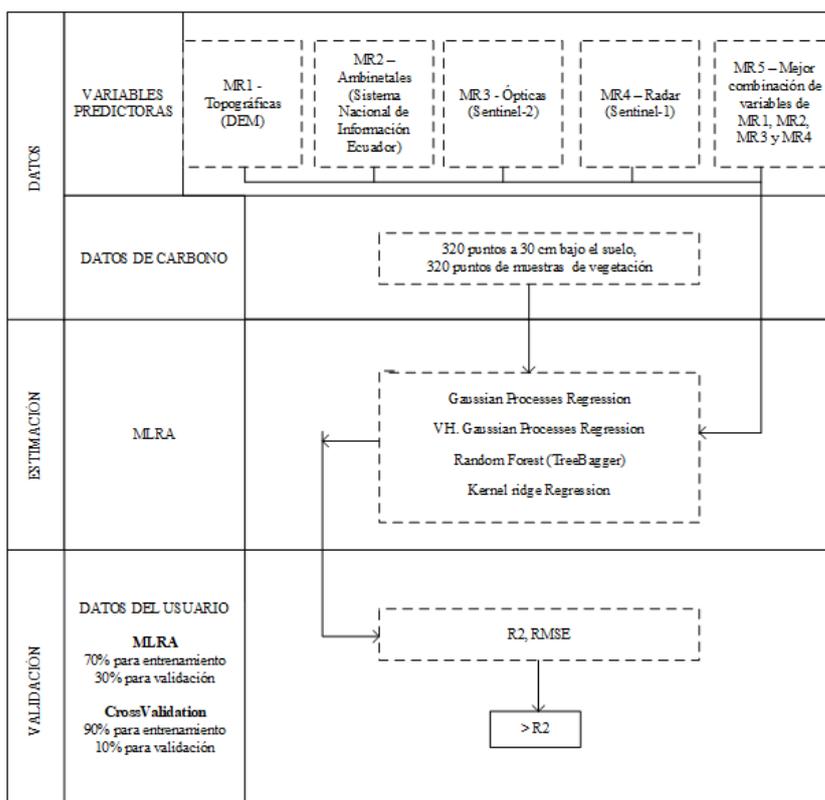


Figura 3.5: Diagrama de la estimación del carbono de la vegetación y del COS, de los 5 modelos de regresión (MR) propuestos

3.2.5. Validación de los modelos de regresión propuestos

En MLRA se realiza la validación con el 30% de los datos recolectados en las campañas de medida. La precisión y rendimiento de los modelos de regresión es evaluada a través del coeficiente de determinación de Pearson R^2 y el error cuadrático medio (RMSE) obtenidos en cada prueba, utilizados como índices de validación tanto para las estimaciones de COS como para el carbono de la

vegetación (Yang et al., 2015): el error cuadrático medio (RMSE) que mide la calidad general de la predicción, el coeficiente de determinación (R^2) que mide la fuerza de la relación lineal entre los valores predichos y observados. Estas variables se definen como:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (3.7)$$

$$R^2 = \frac{\sum_{i=1}^n (P_i - \bar{O})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (3.8)$$

donde P_i y O_i son las estimaciones previstas y observadas; n es el número de muestras; \bar{O} son las medias de las estimaciones observadas. La validación se realizó para el carbono de la vegetación y el COS, asumiendo que el modelo con el R^2 más alto y el RMSE más bajo es el modelo más preciso (Wang et al., 2018).

Resultados

En los siguientes capítulos se presentan los resultados obtenidos en este estudio. En el capítulo 4 se analizan diferentes modelos de clasificación para el cartografiado de peatlands. En el capítulo 5, se realiza una cuantificación del carbono en la vegetación comparado distintos modelos de regresión. El capítulo 6 incluye la estimación del carbono bajo el suelo en el horizonte de 0 a 30 cm a través de modelos de regresión.

Capítulo 4

Cartografiado de peatlands

El capítulo cuarto contiene el análisis de la aplicación del clasificador Random Forest, usando datos obtenidos de Landsat-8 y Sentinel-2 como el primer modelo de clasificación, las variables biofísicas de Sentinel-2 como el segundo modelo, las bandas de la imagen Sentinel-2 como el tercer modelo, ocho índices de vegetación de la imagen Sentinel-2 como el cuarto modelo y la combinación de todas las variables del segundo, tercero y cuarto como el quinto modelo. De esta forma se determina el modelo de clasificación más preciso para la identificación de peatlands.

4. Cartografiado de peatlands

Los modelos de clasificación para discriminar los peatlands son comparados en base a las estadísticas resultantes del proceso de validación (sección 3.2.3). La Tabla 4.1 muestra los resultados de la matriz de confusión, obtenidos en RF con la imagen Landsat-8 en el MC1. A partir del porcentaje de correctos validados con el subconjunto de datos OOB, se obtuvo 77,90% del porcentaje global de correctos con un total de 4217 píxeles para el entrenamiento del algoritmo. Se observa también que dentro de la categoría [Peatland] el mejor clasificado es el nivel de *peatland intervenido* (72,76%), mientras que en la categoría no peatland, denominada [Otros] se clasifican bien casi todos los píxeles (95,15%).

Tabla 4.1: Matriz de confusión del MCI con Landsat-8 (Jara et al., 2019)

Descripción		Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel			
Categoría	Nivel			[1]	[2]	[3]	[4]
Peatland	Peatland intervenido [1]	1252	72,76%	911	270	50	21
	Medianamente conservado [2]	1175	58,38%	322	686	136	31
	Conservado [3]	57	68,42%	5	13	39	0
Otros	Otros [4]	1733	95,15%	35	49	0	1549
Total puntos (píxeles)		4217					
Porcentaje promedio de correctos		73,68%					
Porcentaje global de correctos		77,90%					

Para facilitar la interpretación, a través de los resultados de RF se puede obtener la importancia relativa de cada una de las variables como se muestran en la Figura 4.1. La importancia relativa está entre 0% y 100% en donde a la variable más importante se le asigna 100%, las demás variables obtienen una mejora porcentual con respecto a la que obtuvo 100%. Para el MC1 EVI2 es el índice de mayor importancia con el 100% y NDVI el menor con 9,52%.

4. Cartografiado de peatlands

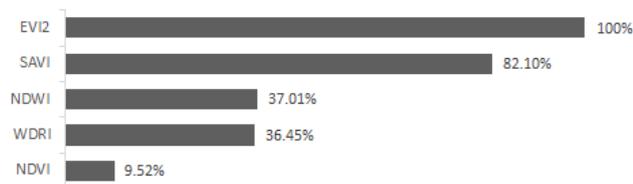


Figura 4.1: Importancia relativa de cada índice en la clasificación de peatlands con Landsat-8 del MCI (Jara et al., 2019)

La Figura 4.2 muestra los resultados de la clasificación del MCI de la imagen Landsat-8. La categoría [Peatland] se distribuye en tres niveles: *peatland intervenido*, con 8120,16 ha (15,41%), *medianamente conservado*, con 12836,07 ha (24,36%) y *conservado* con 752,31 ha (1,43%), con los colores verde, mostaza y azul respectivamente, dando un total de 21708,54 ha (41,21%), mientras que para la categoría [Otros] (color marrón) corresponde a un área de 30975,66 ha (58,79%), del total de 52684,2 ha de la RPFCH (Jara et al., 2019).

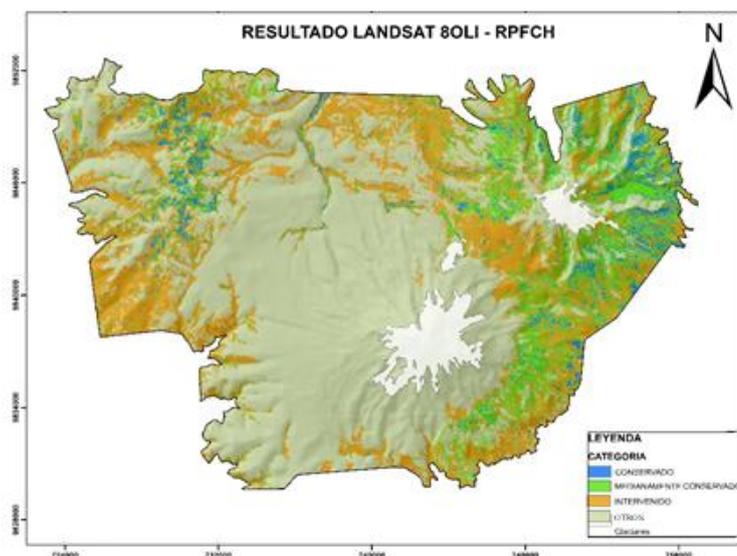


Figura 4.2: Clasificación a partir del MCI de la imagen Landsat-8

4. Cartografiado de peatlands

En la Tabla 4.2 se muestra la matriz de confusión, como resultado de la aplicación de RF, a los índices obtenidos de la imagen Sentinel-2 en el MC1. A partir del porcentaje de correctos validados con el subconjunto de datos OOB, se obtuvo 86,59% del porcentaje global de correctos, con un total de 48540 píxeles usados para el entrenamiento del algoritmo. Se observa que el mejor clasificado es [Otros], mientras que en la categoría [Peatland] el mejor es el nivel *conservado*. A través de los resultados de RF se pudo obtener la importancia relativa de cada uno de los índices, que se muestran en la Figura 4.3, observando a REDEEDGE con la mayor y NDVI con la menor. En la Figura 4.4 se muestra la clasificación obtenida con Sentinel-2. Respecto a la categoría [Peatland], esta se distribuye en tres niveles: *peatland intervenido*, con 12818,69 ha (24%), *medianamente conservado*, con 6112,05 ha (12%) y *conservado* con 1587,29 ha (3%), con los colores verde, mostaza y azul respectivamente, dando una suma total de 20518,03 ha (38,95%), mientras que la categoría [Otros] (color marrón) corresponde a un área de 32165,61 ha (61,05%) del total de 52683,64 ha de la RPFCH (Jara et al., 2019).

Tabla 4.2: Matriz de confusión de los entrenamientos con Sentinel-2 del MC1 (Jara et al., 2019)

Descripción		Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel			
Categoría	Nivel			[1]	[2]	[3]	[4]
Peatland	Peatland intervenido [1]	12845	95,00%	12203	129	382	131
	Medianamente conservado [2]	33294	82,60%	2509	27501	3115	169
	Conservado [3]	1441	96,25%	18	36	1387	0
Otros	Otros [4]	960	98,13%	11	7	0	942
Total puntos (píxeles)		48540					
Porcentaje promedio de correctos		93,00%					
Porcentaje global de correctos		86,59%					

4. Cartografiado de peatlands

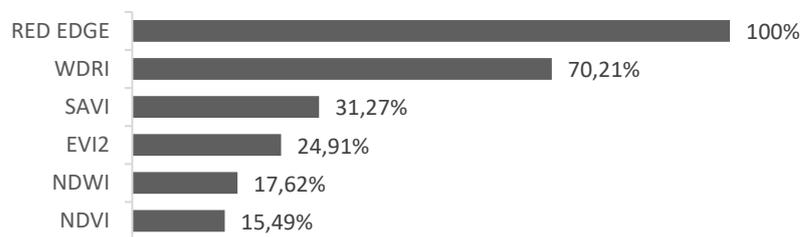


Figura 4.3: Importancia relativa de cada índice en la clasificación de peatlands con Sentinel-2 del MCI (Jara et al., 2019)

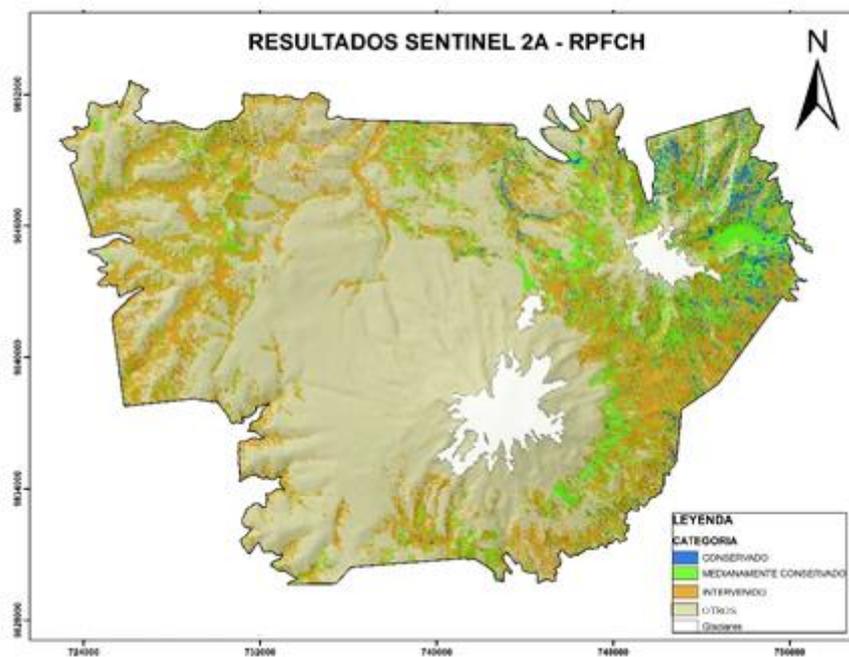


Figura 4.4: Clasificación a partir del modelo MCI de la imagen Sentinel-2

4. Cartografiado de peatlands

En la Tabla 4.3 se muestran los resultados de la matriz de confusión, obtenidos de los entrenamientos en RF, de las variables biofísicas de la imagen Sentinel-2 en el MC2. A partir del porcentaje de correctos validados con el subconjunto de datos OOB, se obtuvo 97% del porcentaje global de correctos, con el uso de 53113 píxeles para el entrenamiento del algoritmo. En la Figura 4.5 se puede observar que en el MC2 fAPAR es la variable de mayor importancia relativa con el 100% y LAI la de menor con el 14,40%. Como resultado del MC2 se obtuvo que a la categoría [Peatland] le corresponde un área de 22366,83 ha (42,46%), mientras que a la categoría [Otros] le corresponde un área de 30316,47 ha (57,54%), del total de 52683,30 ha de la RPFCH.

Tabla 4.3: Matriz de confusión de los entrenamientos con las variables biofísicas de Sentinel-2 del MC2

Descripción	Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel	
			[1]	[2]
Categoría			50523	2590
Peatland [1]	52101	96,96%	50515	1586
Otros [2]	1012	99,21%	8	1004
Total puntos (píxeles)	53113			
Porcentaje promedio de correctos		98,08%		
Porcentaje global de correctos		97,00%		

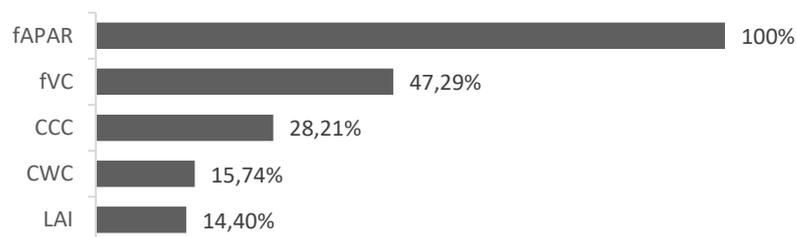


Figura 4.5: Importancia relativa de cada variable biofísica, en la clasificación de peatlands con Sentinel-2 del MC2

4. Cartografiado de peatlands

En la Tabla 4.4 se muestran los resultados de la matriz de confusión, obtenidos de los entrenamientos en RF, de las bandas de la imagen Sentinel-2 en el MC3. A partir del porcentaje de correctos validados con el subconjunto de datos OOB, se obtuvo 98,06% del porcentaje global de correctos, con el uso de 53113 píxeles para el entrenamiento del algoritmo. La importancia relativa de cada una de las bandas se muestra en la Figura 4.6, en la que B4-665 nm es la banda de mayor importancia relativa con el 100% y B12 la menor con el 14,40%.

Tabla 4.4: Matriz de confusión de los entrenamientos con las bandas de la imagen Sentinel-2 del MC3

Descripción	Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel	
			[1]	[2]
Categoría			51094	2019
Peatland [1]	52101	98,04%	51082	1019
Otros [2]	1012	98,81%	12	1000
Total puntos (píxeles)	53113			
Porcentaje promedio de correctos		98,43%		
Porcentaje global de correctos		98,06%		

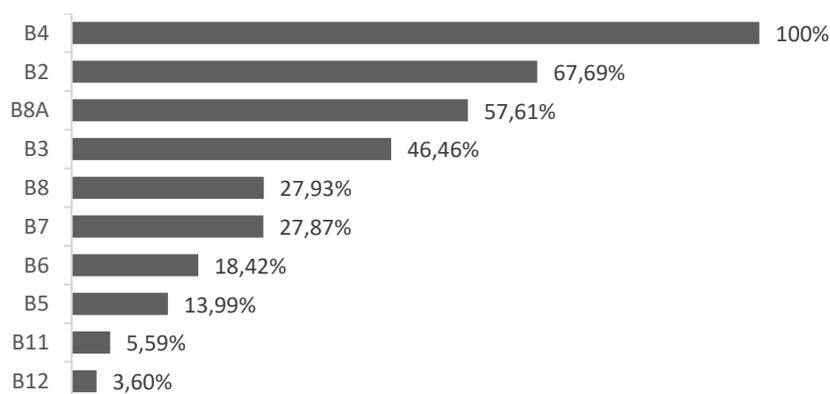


Figura 4.6: Importancia relativa de cada banda, en la clasificación de peatlands con Sentinel-2 del MC3

4. Cartografiado de peatlands

La Tabla 4.5 muestra los resultados de la matriz de confusión con RF, de los 8 índices espectrales calculados con la imagen Sentinel-2 en el MC4. Con el 98,27% del porcentaje global de correctos, usando 53113 píxeles. La Figura 4.7 muestra la importancia relativa: SAVI con la mayor (100%) seguida de REDEEDGE con 89,99%. Con el MC4 se obtuvo que a la categoría [Peatland] le corresponde un área de 23291,71 ha (44,21%), mientras que a la categoría [Otros] le corresponde un área de 29391,59 ha (55,79%), del total de 52683,30 ha de la RPFCH.

Tabla 4.5: Matriz de confusión de los entrenamientos con los 8 índices de Sentinel-2 del MC4

Descripción	Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel	
			[1]	[2]
Categoría			51.212	1.901
Peatland [1]	52.101	98,27%	51.198	903
Otros [2]	1.012	98,62%	14	998
Total puntos (píxeles)	53.113			
Porcentaje promedio de correctos		98,44%		
Porcentaje global de correctos		98,27%		

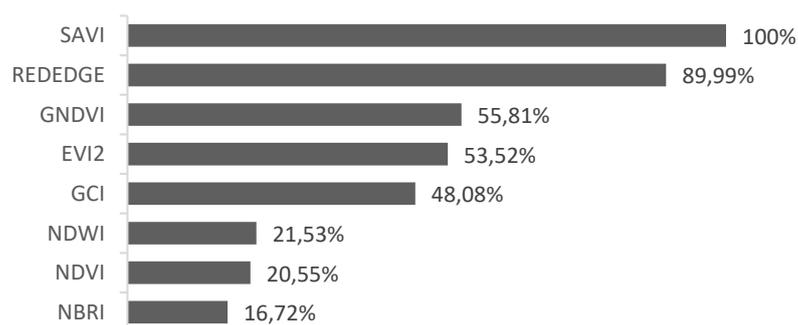


Figura 4.7: Importancia relativa de los 8 índices, en la clasificación de peatlands con Sentinel-2 del MC4

4. Cartografiado de peatlands

La Tabla 4.6 muestra los resultados de la matriz de confusión con RF, de las 23 variables de la imagen Sentinel-2 en el MC5, con el 98,09% del porcentaje global de correctos, usando 53113 píxeles. La Figura 4.8 muestra a las variables fAPAR, REDEEDGE y SAVI con los valores más altos de importancia relativa con 100%, 81,31% y 69,91% respectivamente.

Tabla 4.6: Matriz de confusión de los entrenamientos con las 23 variables de Sentinel-2 del MC5

Descripción	Total de píxeles	Porcentaje de correctos	Predicción – Categoría /Nivel	
			[1]	[2]
Categoría			51110	2003
Peatland [1]	52101	98,08%	51099	1002
Otros [2]	1012	98,91%	11	1001
Total puntos (píxeles)	53113			
Porcentaje promedio de correctos		98,49%		
Porcentaje global de correctos		98,09%		

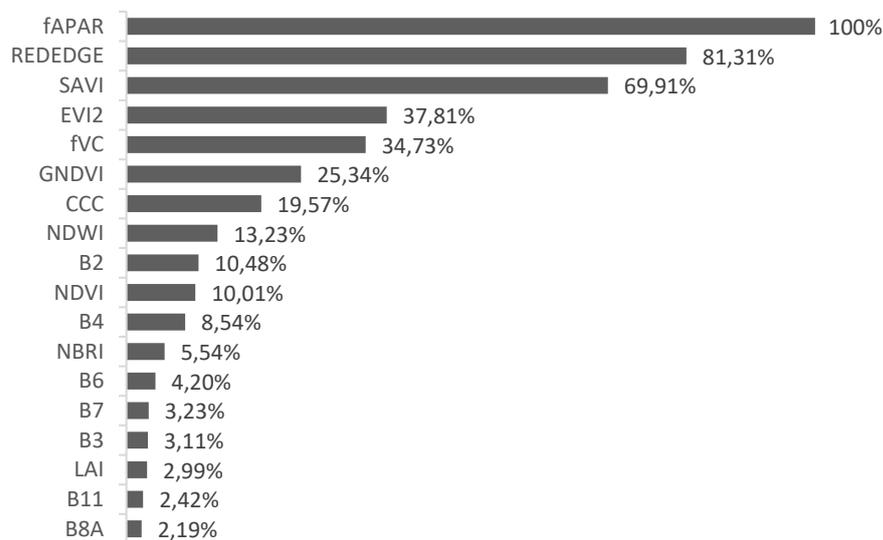


Figura 4.8: Importancia relativa de las variables del MC5, en la clasificación de peatlands con Sentinel-2 mayor al 2%

4. Cartografiado de peatlands

En la Tabla 4.7 se muestra un resumen de los resultados de la clasificación en RF de los cinco modelos, en donde se puede observar que MC4 obtiene el valor más alto del porcentaje global de correctos (98,27%), correspondiente a los 8 índices de vegetación obtenidos de la imagen Sentinel-2, en la Figura 4.9 se representa el mapa con los resultados de MC4 como mejor modelo de clasificación para la representación de los humedales altoandinos (peatlands).

Tabla 4.7: Resumen de los resultados de la clasificación en RF, de los cinco modelos propuestos para el cartografiado de peatlands

Modelo de clasificación	Porcentaje Global	Porcentaje Promedio	Área peatland (ha)
MC4 - 8 índices S2	98.27%	98.44%	23291,71
MC5 - 23 variables S2	98.09%	98.49%	-
MC3 - 10 bandas S2	98.06%	98.43%	-
MC2 - 5 variables biofísicas S2	97%	98.08%	22366,83
MC1 - L8 vs. S2	L8(77,90%) S2(86,59%)	L8(73,68%) S2(93,00%)	21708,54 20518,03

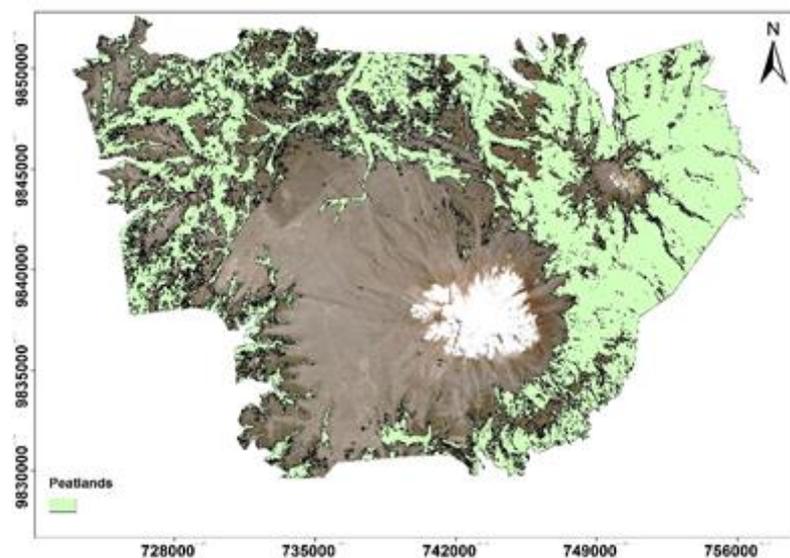


Figura 4.9: Clasificación obtenida a partir del modelo MC4 – 8 índices de vegetación de la imagen Sentinel-2

Capítulo 5

Carbono de la vegetación

El capítulo quinto muestra los resultados del estudio del carbono de la vegetación. Contiene el análisis de la aplicación del test de regresión MLRA de ARTMO a los datos obtenidos en los 5 modelos de regresión propuestos: el MC1 con variables topográficas, el MC2 con ambientales, el MC3 con Sentinel-2, el MC4 con Sentinel-1 y el MR5 con las mejores variables de los modelos 1,2,3 y 4. De esta forma se determina el modelo de regresión más preciso para la estimación del carbono vegetal en peatlands en este estudio. Además, se realiza un estudio calculando la pérdida de carbono entre 2017 y 2020 y finalmente se analiza si existe relación entre los productos automáticos de Sentinel-2 y los datos de campo.

5. Carbono de la vegetación

Tal y como se comentó en el capítulo 2, se midió el contenido en agua y la biomasa (AGB) en 320 muestras de vegetación. En la Figura 5.1 se muestra el diagrama de dispersión entre el AGB y el contenido en agua de los 320 datos de campo. La relación indica que la vegetación de la zona tiene alrededor de 1,6 veces más de contenido en agua que de AGB, lo que concuerda con la descripción de los peatlands al ser ecosistemas con alto nivel de humedad en la vegetación.

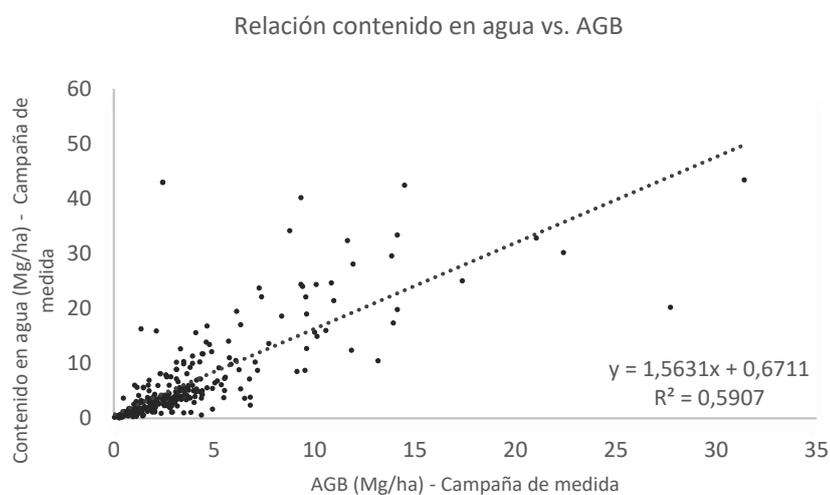


Figura 5.1: Relación entre el contenido en agua y el AGB de la vegetación de los peatlands

5.1. Estimación del carbono de la vegetación, aplicando Machine Learning Regression Algorithm de ARTMO

Como se menciona en el apartado 2.2.2, se asume que la concentración de carbono de la vegetación de los peatlands es el 50% del AGB. Además, en la Figura 3.5 se describen los 5 modelos de regresión propuestos. En la Tabla 5.2 se muestra, para cada modelo de regresión, las variables en orden de importancia y las estadísticas resultantes de la aplicación de 4 métodos MLRA en ARTMO en orden descendente a partir del valor de R^2 . En el caso del carbono de la vegetación, la combinación óptima es de 5 variables para el MR5 donde se obtiene el R^2 más alto de 0,76.

Tabla 5.1: MLRA de ARTMO, aplicado a los 5 MR propuestos para la estimación del carbono de la vegetación. Todas las variables se muestran ordenadas de acuerdo a su importancia de mayor a menor. En MR1, MR2 y MR5 se muestran todas las variables, mientras que en MR3 y MR4 solo se muestran las más importantes; los métodos de MLRA están en orden descendente en base al valor del coeficiente de determinación

	VARIABLES	MLRA	R^2	RMSE ($\frac{Mg}{ha}$)
MR1 Topográficas	Elevación,	VH. Gaussian Processes Regression	0,49	1,62
	pendiente,	Gaussian Processes Regression	0,47	1,73
	TWI	Random Forest	0,43	1,75
		Kernel ridge Regression	0,32	1,93
MR2 Ambientales	Ecosistema,	Random Forest	0,67	1,18
	usos,	Gaussian Processes Regression	0,64	1,22
	taxonomía,	VH. Gaussian Processes Regression	0,60	1,39
	textura,	Kernel ridge Regression	0,43	1,52
	temperatura, precipitación, distancia a ríos.			

5. Carbono de la vegetación

MR3 Sentinel-2	REDEDGE,	VH. Gaussian Processes Regression	0,49	1,68
	LAI,	Gaussian Processes Regression	0,48	1,69
	NBRI	Kernel ridge Regression	0,37	1,78
		Random Forest	0,28	2,17
MR4 Sentinel-1	Promedio (VV/VH),	VH. Gaussian Processes Regression	0,20	1,04
	promedio (VH/VV)	Gaussian Processes Regression	0,14	1,28
		Kernel ridge Regression	0,05	1,35
		Random Forest	0,05	1,35
MR5 Mejor combinación	Elevación,	Gaussian Processes Regression	0,76	1,11
	precipitación,	VH. Gaussian Processes Regression	0,69	1,29
	promedio (VV/VH),	Random Forest	0,69	1,33
	NBRI,	Kernel ridge Regression	0,56	1,51
	LAI			

Para determinar la importancia de las variables, MLRA de ARTMO utiliza un valor denominado sigma, que proporciona un indicador de la relevancia de las variables de entrada; cuanto más bajo es el sigma, más importante es la variable (Verrelst & Rivera, 2018b). Para el carbono de la vegetación en MR5 con GPR, las variables en orden de importancia en base a sigma son: de las topográficas *elevación*, de las ambientales *precipitación*, de las radar *promedio (VV/VH)* y de las ópticas *NBRI* y *LAI*, como se observa en la Figura 5.2. Se muestra también el polar plot en la Figura 5.3 en donde las variables más importantes están más alejadas del centro.

5. Carbono de la vegetación

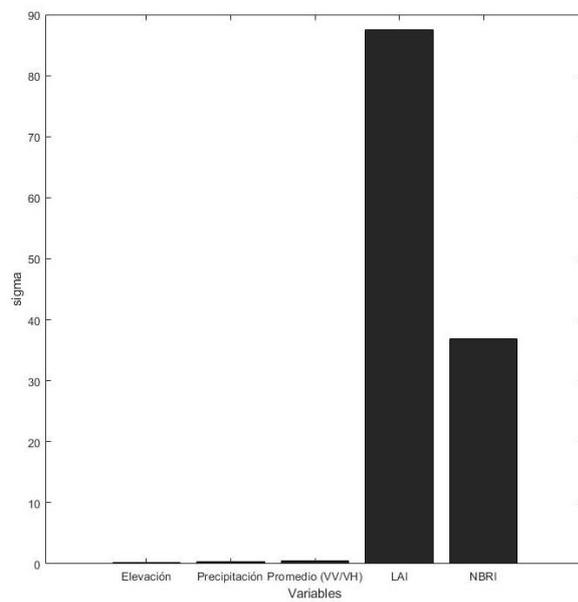


Figura 5.2: Sigma de las variables de MR5 para el carbono de la vegetación

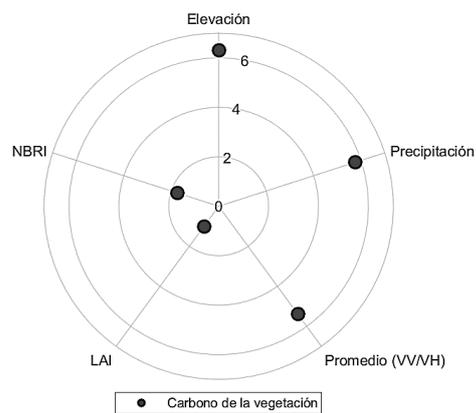


Figura 5.3: Relevancia de las variables del MR5 con GPR para el carbono de la vegetación.

En la Figura 5.4 se puede visualizar el rendimiento de la predicción, mediante la gráfica resultante de la relación de los datos estimados versus los medidos con barras de incertidumbre, en base a los valores de la desviación estándar, con respecto al carbono de la vegetación en $\frac{Mg}{ha}$, con el MR5. Además se puede apreciar que existe mayor concentración en el rango de 0 a 2 $\frac{Mg}{ha}$ y que la mayoría de los puntos están alrededor de la línea 1:1, situación similar en los demás métodos utilizados como muestra la Figura 5.5.

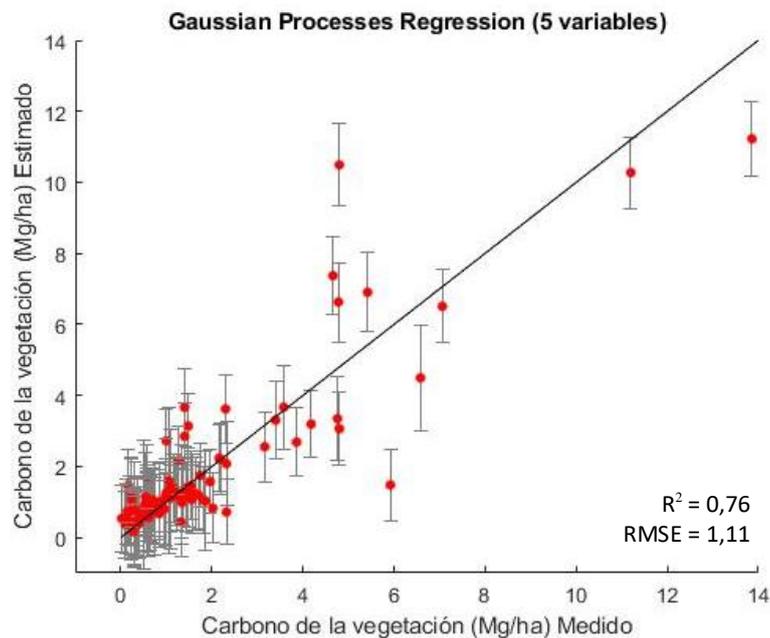


Figura 5.4: Carbono de la vegetación con GPR para MR5 (Estimado vs. Medido) con barras de incertidumbre en base a la desviación estándar. Se muestra la línea 1:1

5. Carbono de la vegetación

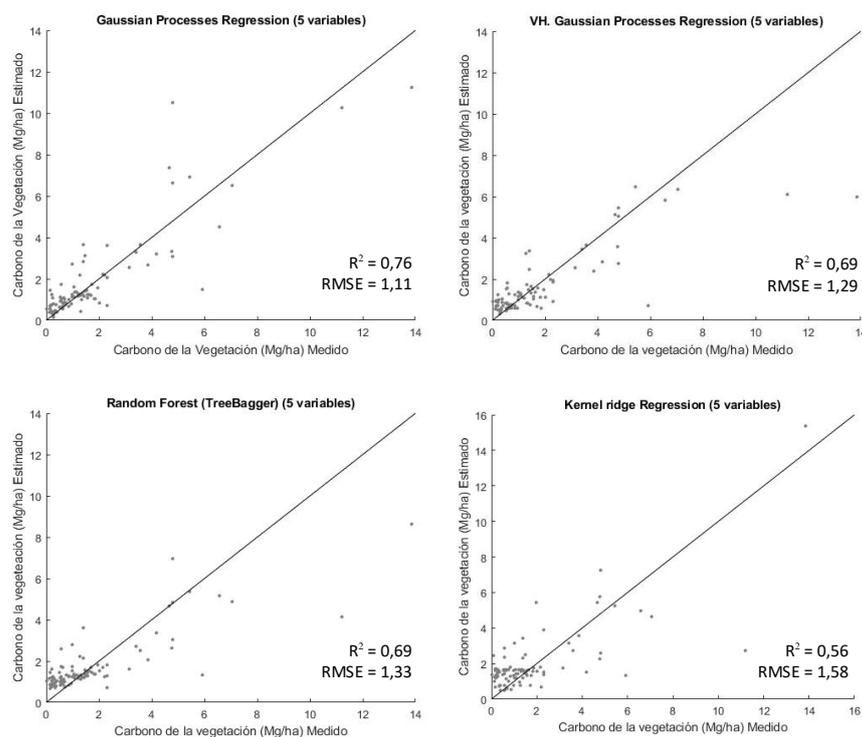


Figura 5.5: Comparativa de la relación Estimado vs. Medido del carbono de la vegetación con el MR5 con los 4 métodos MLRA. Se muestra la línea 1:1

Para la estimación del carbono de la vegetación en los peatlands del área de estudio, la variable más importante fue *elevación* obtenida del DEM, seguida de la *precipitación*. El *promedio VV/VH* es la variable que ocupa el tercer lugar de importancia, coincidiendo con los resultados de Rudiyanto et al. (2018) que obtiene a la relación VV/VH de imágenes radar de Sentinel-1 como una de las de mayor influencia en el modelado del carbono de peatlands en su estudio. La cuarta variable más importante fue el índice de tasa de combustión normalizada (*NBRI*), dentro de los índices calculados a partir de Sentinel-2. NBRI ha sido utilizado para monitorear el crecimiento de la vegetación después de incendios, pero la sensibilidad a la

humedad foliar y a la densidad de la vegetación ha permitido su uso para la caracterización de la misma. La combinación de Green-Red Vegetation Index (GRVI) y NBRI en los modelos de regresión mejora significativamente la determinación de la biomasa aérea (Morley et al., 2019).

La quinta variable más importante fue *LAI*. Las evaluaciones oportunas de *LAI* y *AGB* combinando imágenes Sentinel-1, Landsat-8 y Sentinel-2 son útiles para la estimación y posterior gestión de pastizales de manera sostenible (Wang et al., 2019). El añadir *LAI* a varios índices de vegetación de Sentinel-2, aumentó la precisión de estimación de biomasa de cultivos de maíz a R^2 de 0.91 (Jin et al., 2020). Los resultados muestran que el modelo basado en el índice biofísico *LAI* derivado de Sentinel-2 fue más preciso en predecir la biomasa general sobre el suelo en el ecosistema manglar (Castillo et al., 2017).

Los datos de las imágenes ópticas han permitido la estimación de la biomasa *AGB* en humedales y en general producen mayor precisión de modelado que imágenes radar de forma independiente (Naidoo et al., 2019; Thomas et al., 2019). Sin embargo la adición de los datos multitemporales de Sentinel-1 a Sentinel-2 han mejorado el rendimiento predictivo (Jensen et al., 2019) para estimar la biomasa aérea de la vegetación de humedales en Sudáfrica, logrando resultados comparables a los del sensor WV3 que es más caro (Naidoo et al., 2019), aumentando el R^2 en un 13,5%. Además con la combinación de variables ambientales se logró mejorar los resultados con el valor más alto de R^2 (0,75) y los valores más bajos de RMSE (0,55 g/kg) (Zhou et al., 2020). Para estimaciones de *AGB* en pastizales, el integrar Sentinel-1, Sentinel-2 y Landsat-8 obtuvo los coeficientes de correlación más altos (0,78) y el RMSE más bajo (119,4 g /m²) utilizando el algoritmo MLR (Wang et al., 2019). Además de estimar la biomasa aérea, las imágenes radar también permiten verificar la precisión en la evaluación de la humedad (Dabrowska-Zielinska et al., 2015). La descomposición polarimétrica para datos radar aumenta ligeramente la precisión de la estimación de *AGB* en vegetación herbácea (Jensen et al., 2019), en contraste con (Byrd et al., 2018) que indica que la inclusión de Sentinel-1 dentro del modelo no pudo mejorar los resultados en zonas pantanosas.

5. Carbono de la vegetación

Sentinel-1 ha demostrado obtener buenos resultados en análisis de textura de cultivos y está siendo utilizada para estimar el estado de humedales y peatlands (Caballero et al., 2020; Lees et al., 2018; Yang & Guo, 2019).

Aunque los modelos de aprendizaje automático basados en árboles de decisión pudieran ser considerados en algunos estudios como los de mejor rendimiento para el cartografiado del peatlands y la evaluación de las reservas de carbono (Rudiyanto et al., 2018), no se ha encontrado que ningún modelo fuera el más sólido en todas las circunstancias (Lamichhane et al., 2019). Sin embargo se ha demostrado que GPR ha superado el rendimiento de otros métodos para modelos de Producción Primaria bruta (GPP) y calor latente de evaporación (Camps-Valls et al., 2015) así como también en la predicción de dióxido de carbono (Fang et al., 2018) y en nuestro estudio fue el método con mayor precisión para la estimación del COS y del carbono de la vegetación. En la Figura 5.6 se puede observar el mapa del carbono de la vegetación, usando solo las variables *elevación*, *precipitación*, *promedio VV/VH*, *NBRI* y *LAI* del modelo MR5 con el método GPR.

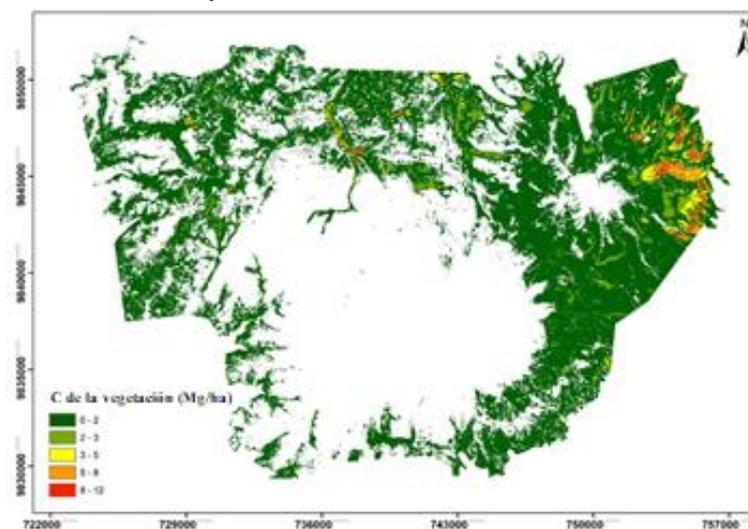


Figura 5.6: Mapa del contenido en carbono de la vegetación ($\frac{Mg}{ha}$) con los resultados de MR5 aplicando MLRA (GPR)

5.2. Uso de Sentinel-2 en la detección de cambios temporales del carbono de la vegetación

Con el fin de analizar la capacidad de predecir el carbono de la vegetación usando solo Sentinel-2, como contribución de la teledetección para detectar cambios de carbono en la vegetación, se compara la imagen del 2017 con una del 2020, a través de un modelo de regresión del carbono de la vegetación (MRCV), propuesto en el presente estudio, generado en el software *ARTMO* con GPR. La reflectancia de los peatlands es analizada mediante 10 bandas (B2-490 nm, B3-560 nm, B4-665 nm, B5-705 nm, B6-740 nm, B7-783 nm, B8-842 nm, B8a-865 nm, B11-1610 nm, B12-2190 nm) que tienen mayor relación con estudios de vegetación, sin tomar en cuenta a las bandas B1, B9 y B10 por estar relacionadas con la estimación de aerosoles, vapor de agua y nubes respectivamente. La base de datos comprende 380 puntos (320 puntos de las campañas de medida, 20 puntos adicionales de suelo desnudo, 20 de roca y 20 de nieve). Las clasificaciones de suelo desnudo, roca y nieve son realizadas por teledetección manual de 60 pines en el software *SNAP* sobre la imagen Sentinel-2, seguida de una comprobación *in situ* de algunos de los puntos.

Como resultado se obtiene un coeficiente de correlación de $R = 0,68$ para el MRCV propuesto. Se muestran las áreas en 5 rangos del carbono de la vegetación (0 – 1,5; 1,5 – 2; 2 – 2,5; 2,5 – 3,5; 3,5 - 15) para las dos imágenes (2017 y 2020). Se puede identificar en la Figura 5.7, que en los dos primeros rangos es menor el área del carbono vegetal para el año 2017, para el rango de 2 a $2,5 \frac{Mg}{ha}$ mantiene una relativa igualdad y para los dos últimos es mayor que el área del 2020, lo que indica una clara pérdida de carbono. En la Tabla 5.2 se muestran los valores numéricos mostrando que el rango de 0 a $1,5 \frac{Mg}{ha}$ aumenta en un 145%, mientras que el de 3,5 a $15 \frac{Mg}{ha}$ disminuye en un -52,49%. Que los rangos bajos del carbono de vegetación aumenten y los altos disminuyan del año 2017 al 2020, puede ser por el cambio de uso de suelo o la variación de la temperatura (León & Reyes, 2018). Los resultados de Vistin-Guamantaqui et al. (2021) muestran un panorama negativo con respecto

5. Carbono de la vegetación

al área de ocupación de algunos ecosistemas alto andinos en la RPFCH, concluyendo que decrecerán debido a los cambios de temperatura y precipitación. Además, un factor adicional que se debe tener en cuenta es el causado por las actividades humanas que producen desequilibrios ecológicos, lo que conlleva a un acelerado proceso de fragmentación y posibles pérdidas de vegetación.

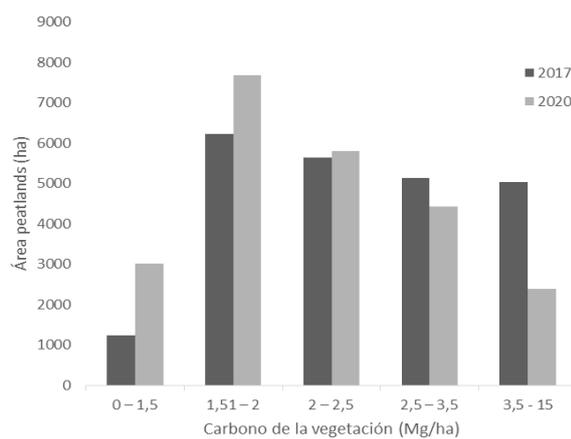


Figura 5.7: Comparación de las áreas de peatlands por rango del carbono de la vegetación (2017 y 2020)

Tabla 5.2: Variación de las áreas de 5 rangos del carbono de la vegetación de las imágenes Sentinel-2 (2017 y 2020)

Rango del carbono de la vegetación en ($\frac{Mg}{ha}$)	Área en la imagen Sentinel-2 del 2017 en ha	Área en la imagen Sentinel-2 del 2020 en ha	% de variación del 2017 con respecto al 2020
0 - 1,5	1228	3006	144,79
1,5 - 2	6235	7677	23,13
2 - 2,5	5650	5794	2,55
2,5 - 3,5	5143	4422	-14,02
3,5 - 15	5035	2392	-52,49

5. Carbono de la vegetación

En la Figura 5.8 se muestran los histogramas del carbono de la vegetación obtenidos con GPR para los años 2017 y el 2020, donde se observa el desplazamiento del histograma hacia la izquierda. Teniendo en cuenta los valores medios y que el área total de los bofedales fue 23292 ha, el carbono total en el área en estudio fue de 71975 Mg en 2017 a 59362 Mg en 2020, mostrando una clara disminución y pérdida de capacidad de almacenaje de carbono en la vegetación.

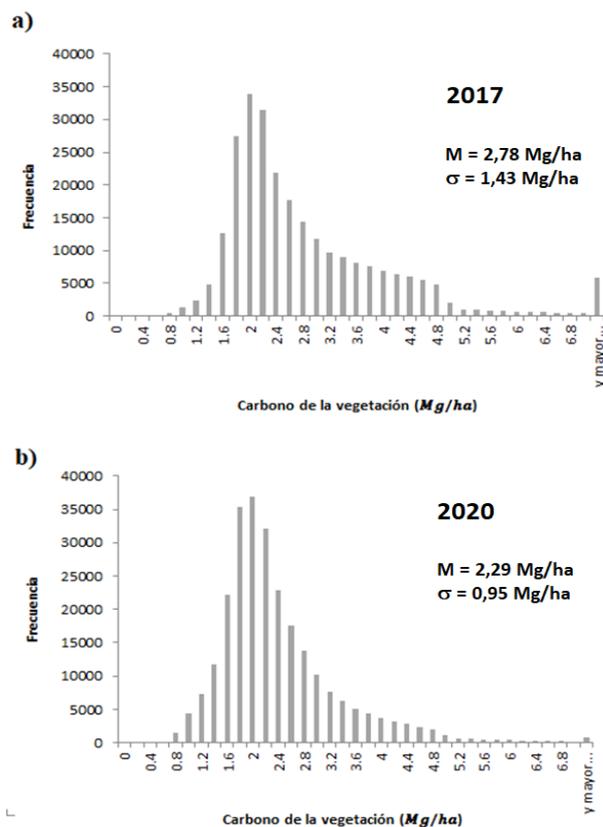


Figura 5.8: Histogramas del carbono de la vegetación obtenido de Sentinel-2 de los años 2017 (a) y 2020 (b). M indica la media y σ la desviación estándar.

5. Carbono de la vegetación

En síntesis, el peatland ha sufrido una clara disminución del carbono vegetal entre 2017 y 2020, como se observa en las Figuras 5.9 y 5.10. Al comparar las dos imágenes se puede apreciar una gran reducción de las zonas que se muestran en rojo (valores más altos de biomasa), principalmente en la zona noreste de la RPFCH, como se puede distinguir mejor en la ampliación a dos distintos niveles de una misma zona en los dos periodos.

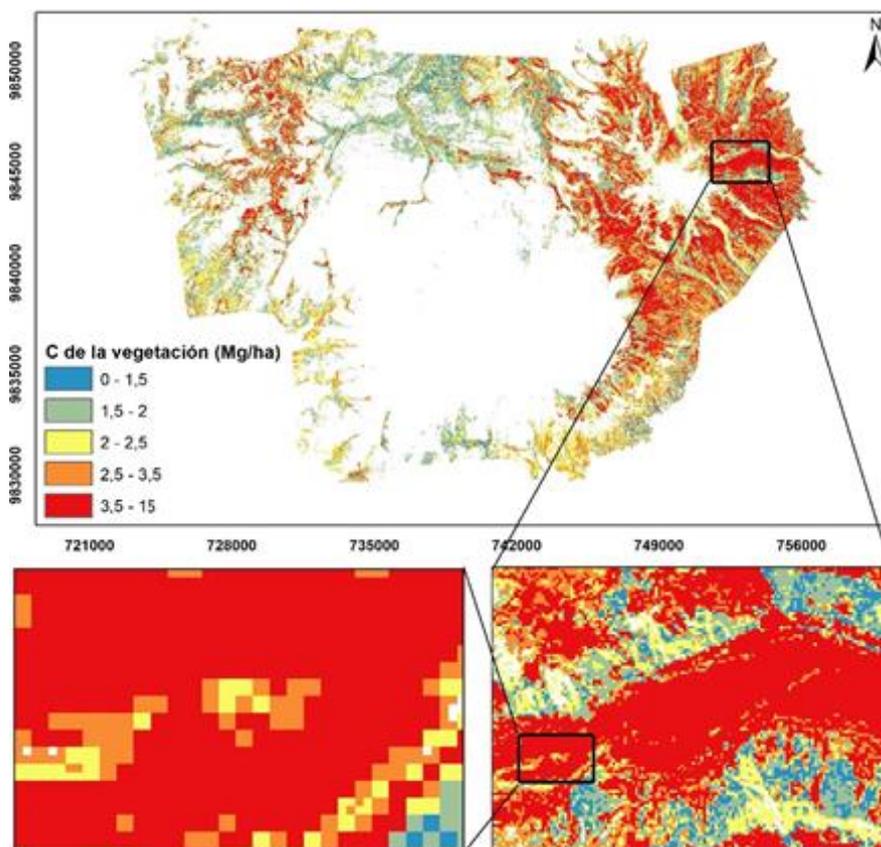


Figura 5.9: Mapa del contenido en carbono de la vegetación con los resultados de MRCV aplicando MLRA (GPR) en la imagen Sentinel-2 del 2017

5. Carbono de la vegetación

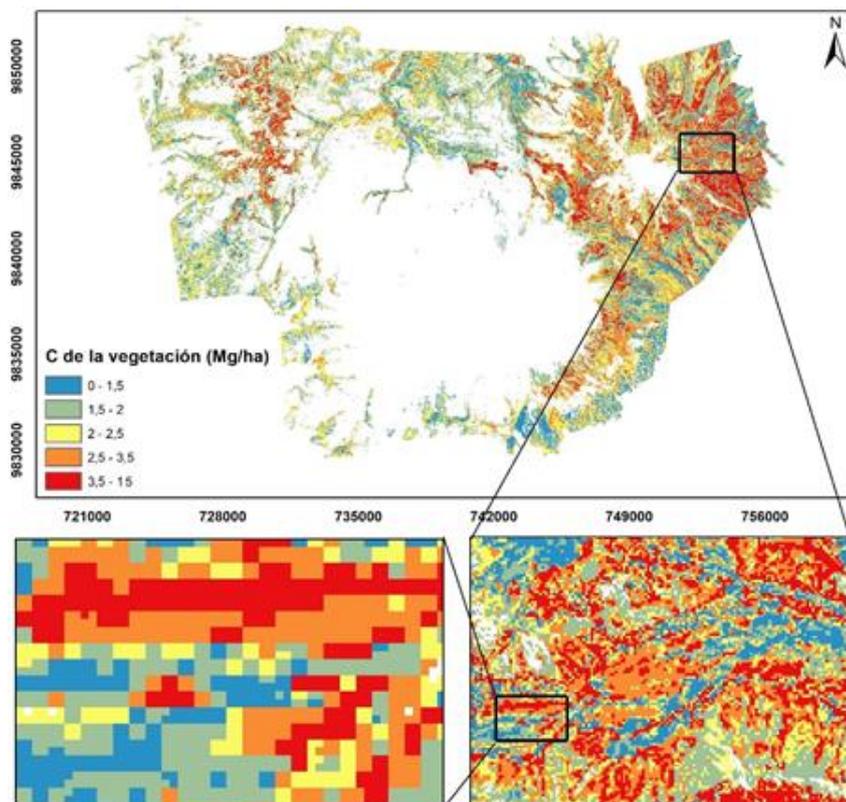


Figura 5.10: Mapa del contenido en carbono de la vegetal con los resultados de MRCV aplicando MLRA (GPR) en la imagen Sentinel-2 del 2020

En la Figura 5.11 se muestra la relevancia de cada banda en la estimación de carbono de la vegetación, usando GPR solo con imágenes Sentinel-2. Como se observa, las bandas más importantes (más lejos del centro) son las bandas B5 y B8a, correspondientes al Red Edge y al NIR respectivamente, concordando parcialmente con los resultados de Castillo et al., (2017) que indican que B4, B5 y B7 con la elevación, fueron la mejor combinación para la predicción de la biomasa en bosques de manglares; lo que tiene correspondencia al encontrarnos analizando una cubierta vegetal. Este resultado confirma la importancia de las bandas del Red

5. Carbono de la vegetación

Edge en estudios de vegetación con Sentinel-2, coincidiendo con otros muchos trabajos (Delegido et al., 2011; Verrelst et al., 2012)

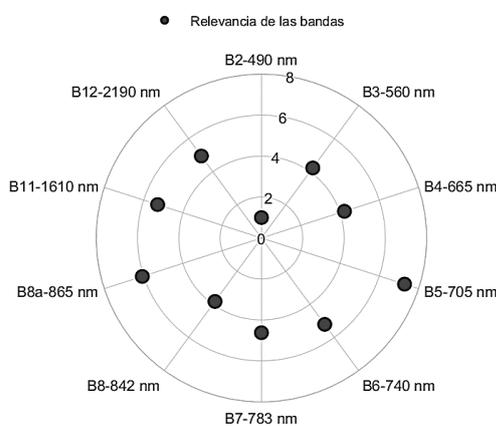


Figura 5.11: Importancia de las bandas en el MRCV propuesto

5.3. Relación de los productos automáticos de vegetación de Sentinel-2 con datos de campo

Se realizó una comparación entre los datos obtenidos en las campañas de medición de la biomasa y del contenido en agua de la vegetación, con los valores de las variables biofísicas obtenidas como productos automáticos de la imagen Sentinel-2 en *SNAP*. Como resultado se obtuvo valores del coeficiente de determinación muy bajos, en el caso del contenido en agua entre 0,0052 y 0,066; con respecto a la biomasa se obtuvo resultados similares, entre 0,0057 y 0,072 correspondientes a CCC y CWC en ambos casos, como se puede observar en la Figura 5.12. Aunque otros autores obtuvieron altas correlaciones entre los productos automáticos y el LAI y la CCC medido en campo en cultivos de trigo en China (Xie et al., 2019), esto pudo deberse a que el estudio se realizó en una área pequeña (3 ha) y con una sola especie de cultivo que puede llegar a medir entre 0,5 a 2 metros de altura; mientras que la RPFCH es un área considerablemente mayor, en la que existen varias especies dentro de los peatlands de estudio y que la especie que se encuentra

5. Carbono de la vegetación

en mayor porcentaje es la conocida comúnmente como almohadilla o musgo, que apenas llega a medir 3 cm de largo, como se pudo observar en la Figura 2.5. De igual forma para la estimación del fAPAR y fVC, modelos de regresión propuestos a partir de índices de vegetación, en comparación con lo obtenido con el procesador biofísico de SNAP en cultivos de trigo, también obtuvieron una alta precisión (0,92 y 0,94) en Bulgaria (Kamenova & Dimitrov, 2021). En conclusión, con los datos obtenidos en las campañas de medida del presente estudio, no se pudo establecer una relación representativa con los productos automáticos de vegetación de Sentinel-2

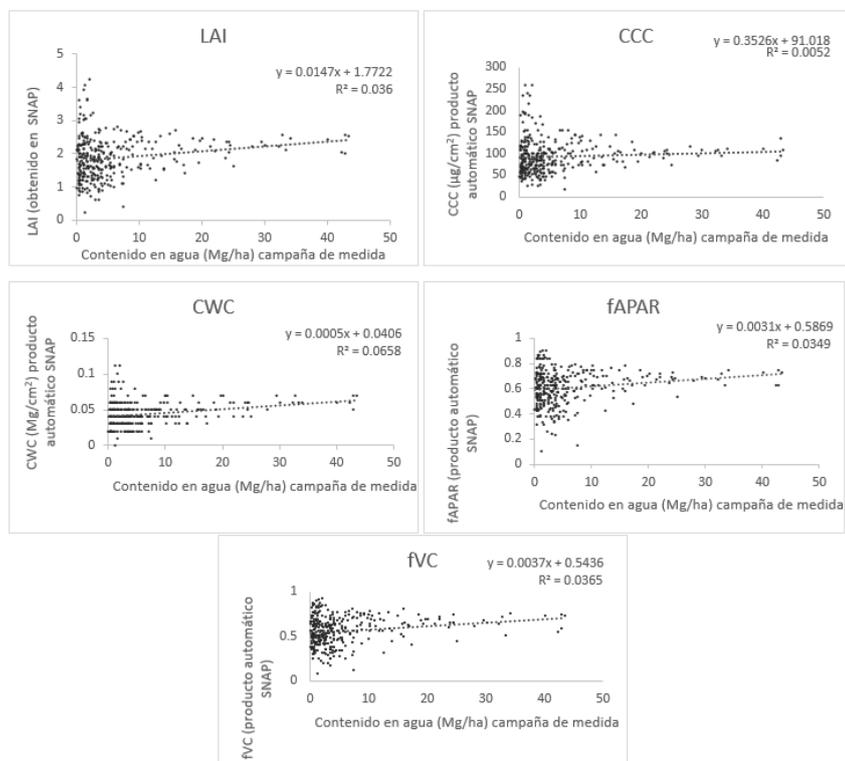


Figura 5.12: Relación de los productos automáticos con el contenido en agua obtenido en campo

Capítulo 6

COS

El capítulo sexto contiene el análisis de la aplicación del test de regresión MLRA de ARTMO para la estimación del carbono en el suelo. Se calibran cinco modelos, evaluando variables de diferente origen y de manera conjunta: el primer modelo se calibra con datos obtenidos de las variables topográficas; el segundo modelo se calibra mediante las variables ambientales; el tercer modelo usa las variables ópticas a partir de Sentinel-2; el cuarto modelo a través de las variables de radar de Sentinel-1; y finalmente el quinto modelo se calibra con todas las variables de los modelos del uno al cuatro. De esta forma es posible determinar el modelo de regresión más preciso para la estimación del COS en los peatlands de la zona de estudio.

6. Carbono bajo el suelo (COS)

La Tabla 6.1 muestra los resultados de la aplicación de cuatro métodos MLRA de ARTMO (GPR, VHGP, RF y KRR) aplicados a los cinco modelos de regresión propuestos. En la Tabla 6.1 se muestra que las variables topográficas y las ambientales que forman el MR1 y el MR2 respectivamente, están fuertemente ligadas a la dinámica de almacenaje del COS por obtener mayores valores de R^2 que las ópticas (MR3) y de radar (MR4). Sin embargo, la calibración del modelo más óptimo resultó ser el MR5, pues alcanzó el R^2 más alto usando GPR con un valor de 0,76. El R^2 de MR5 logrado con GPR supera al obtenido con los otros métodos; con respecto a los mejores métodos identificado en los modelos MR1 y MR2, el R^2 de MR5 tiene un incremento entre 0,19 y 0,20 (ver Tabla 6.1). Tomando en cuenta únicamente los resultados con GPR, para todos los modelos de regresión propuestos para la estimación del COS, podemos determinar que el MR5 es 10% más efectivo que el MR1, 11% que el MR2, 53% que el MR3 y 64% que el MR4.

Tabla 6.1: MLRA de ARTMO, aplicado a los 5 MR para la estimación del COS. Las variables se encuentran ordenadas de acuerdo a su importancia de mayor a menor. En MR1, MR2 y MR5 se muestran todas y en MR3 y MR4 se muestran únicamente las variables de mayor importancia. Los métodos de MLRA están en orden descendente en base al valor del coeficiente de determinación

	VARIABLES	MLRA	R^2	RMSE ($\frac{Mg}{ha}$)
MR1 Topográficas	Elevación,	VH. Gaussian Processes Regression	0,57	0,90
	pendiente,	Gaussian Processes Regression	0,56	0,92
	TWI	Random Forest	0,28	1,17
		Kernel ridge Regression	0,19	1,26

6. COS

MR2 Ambientales	Ecosistema,	Random Forest	0,56	0,97
	usos,	Gaussian Processes Regression	0,55	0,97
	taxonomía, textura,	VH. Gaussian Processes Regression	0,54	0,98
	temperatura, precipitación, distancia a ríos.	Kernel ridge Regression	0,50	1,02
MR3 Sentinel-2	REDEDGE,	VH. Gaussian Processes Regression	0,24	1,23
	LAI,	Gaussian Processes Regression	0,23	1,23
	NBRI	Kernel ridge Regression	0,17	1,25
		Random Forest	0,05	1,39
MR4 Sentinel-1	Promedio(VH/VV),	VH. Gaussian Processes Regression	0,12	2,08
	promedio(VV/VH)	Gaussian Processes Regression	0,12	2,09
		Kernel ridge Regression	0,12	2,18
		Random Forest	0,07	2,20
MR5 Mejor combinación	Elevación,	Gaussian Processes Regression	0,76	0,69
	usos,	VH. Gaussian Processes Regression	0,74	0,71
	temperatura,	Random Forest	0,71	0,77
	distancia a ríos, precipitación, REDEDGE, promedio (VH/VV).	Kernel ridge Regression	0,63	0,85

Como se muestra en la Figura 6.1, la combinación óptima para la estimación del COS para el MR5 con GPR es de 7 variables, de acuerdo al siguiente orden determinado por sigma: de las topográficas, *elevación*; de las ambientales, *usos*, *temperatura*, *distancia a ríos* y *precipitación*; de las ópticas, *REDEDGE* y de las radar el *promedio (VH/VV)*. Además, se muestra en la Figura 6.2 el polar plot en donde las variables más relevantes están más lejos del centro.

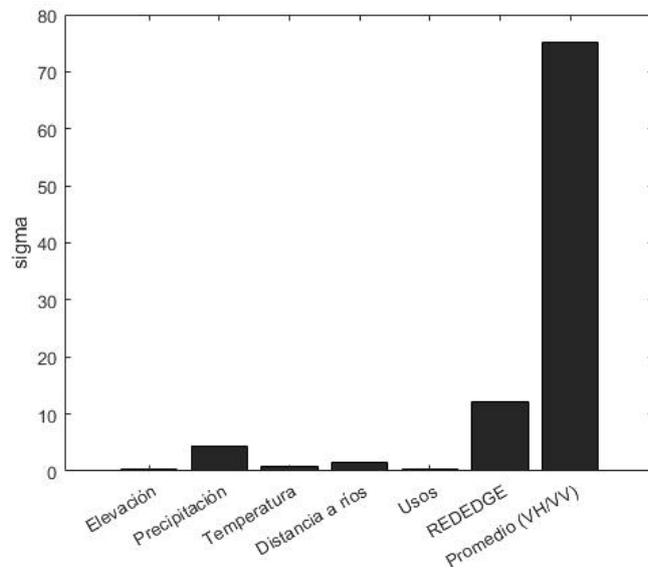


Figura 6.1: Sigma de las variables de MR5 para la estimación del COS

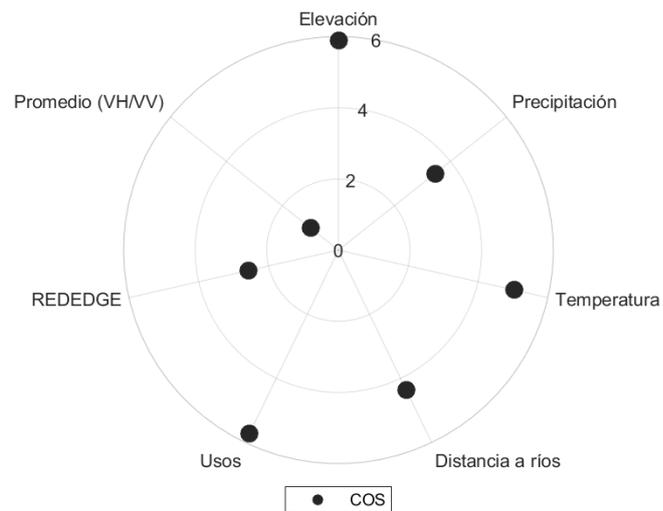


Figura 6.2: Importancia de las variables para la estimación del COS con GPR para MR5

6. COS

En la Figura 6.3 se muestran los gráficos que representan los valores estimados frente a los medidos en campo de los cuatro métodos MLRA usados para la estimación del COS. En ella se observa una distribución equilibrada de puntos con respecto a la línea 1:1. En la Figura 6.4 se ha representado también la relación de lo estimado versus lo medido con barras de incertidumbre en base a los valores de la desviación estándar para el método que mejores resultados obtuvo (GPR).

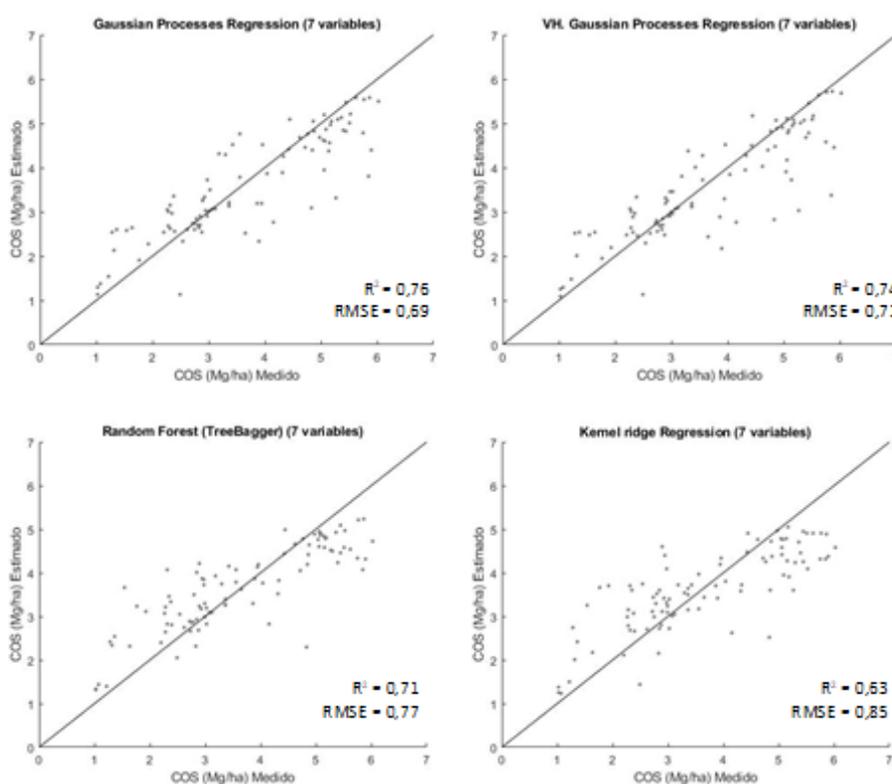


Figura 6.3: Resultados de la relación Estimado vs. Medido en MLRA del COS con el MR5

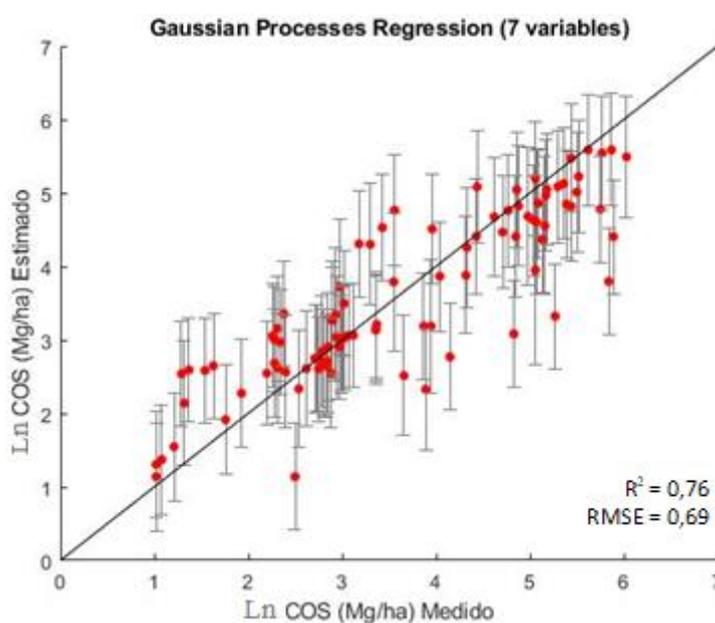


Figura 6.4: Ln COS con GPR para MR5 (Estimado vs. Medido)

Para la estimación del COS en los peatlands del área de estudio, la variable más importante en el MR5 del MLRA con GPR, fue *elevación* obtenida a partir del DEM, concordando con otros estudios que han determinado que las concentraciones más altas de COS se encuentran en lugares a gran altitud donde las tasas de precipitación son más altas (Rial et al., 2017) y a diferencia de otros estudios que determinan que la geología es el factor más importante para predecir el COS (Guo et al., 2015). Para el cartografiado de peatlands en extensiones regionales, de acuerdo a Lamichhane et al., (2019) el clima es el factor más importante en los niveles de COS, junto con la topografía y el uso de la tierra que fue la segunda variable más importante en nuestro estudio, definida como *usos*. Si bien la *temperatura* afecta el nivel de COS en la capa superficial del suelo, la *precipitación* influye más en el subsuelo (Lamichhane et al., 2019; Zhou et al.,

6. COS

2020), ocupando las posiciones tres y cinco respectivamente. La variable *distancia a ríos* ocupa el lugar número cuatro. Con respecto a las variables obtenidas a partir de la imagen Sentinel-2, REDEEDGE estuvo dentro de las variables más importantes para la estimación del COS, específicamente en la posición número seis, coincidiendo parcialmente con Ruidiyanto et al., (2018) que indica que las imágenes ópticas son los predictores más importantes del cartografiado de peatlands y la evaluación de reservas de carbono. REDEEDGE también ha mostrado su importancia para la estimación de parámetros biofísicos como Green LAI y Clorofila (Delegido et al., 2011; Rivera et al., 2011). Es probable que el mejor modelo para las estimaciones de carbono en peatlands se base en longitudes de onda visibles y NIR (Lees et al., 2018), coincidiendo con otros estudios donde destacan índices como NDVI y EVI (Lees et al., 2018). La relación VH / VV en Sentinel-1 es útil para predecir el COS según Yang et al. (2019), coincidiendo parcialmente con nuestro estudio, al ser una variable con cierta importancia para el mejor modelo de estimación del COS, en el lugar número siete.

Los datos radar son utilizados con menos frecuencia que los ópticos, a pesar de ello han demostrado ser una fuente importante en la estimación del carbono (Yang & Guo, 2019). La combinación de la teledetección óptica y por radar, mejora la precisión en estimaciones regionales de carbono del suelo en peatlands, así como también en la identificación de los tipos de ecosistemas y vegetación por estar asociados con el carbono subterráneo (Draper et al., 2014). Incluir radar para cartografiar peatlands en regiones montañosas sería un enfoque sólido para proporcionar mapas a escala nacional para Ecuador y otras regiones (Hribljan et al., 2017). En general al utilizar datos radar, la precisión predictiva disminuye al aumentar la profundidad, así como también puede ser más sensibles a la variación de la vegetación, principalmente durante el período de reverdecimiento más que en otras fases de crecimiento (Yang & Guo, 2019). Sentinel-1 ha demostrado que el carbono orgánico del suelo y la densidad aparente pueden predecirse con éxito con datos de series temporales radar en humedales en la costa este-central de China (Caballero et al., 2020; Lees et al., 2018; Yang & Guo, 2019).

En la Figura 5.9 se puede observar el mapa del carbono orgánico del suelo, con el MR5 aplicando el método de modelado GPR en MLRA de ARTMO. A partir del mapa se pudo estimar que la cantidad de carbono total en el área de estudio, almacenada en el suelo en la capa 30 cm, fue de 13639407 Mg.

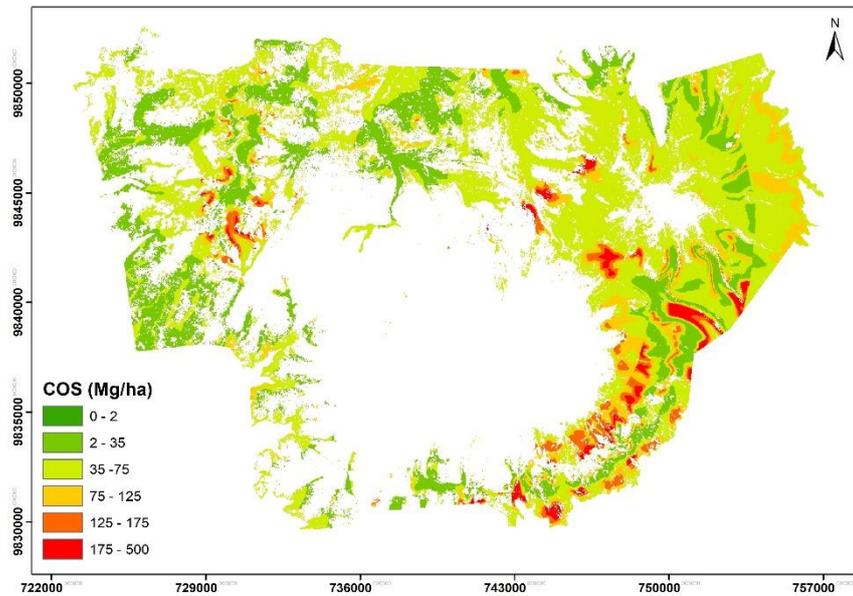


Figura 5.9: Mapa del COS (Mg/ha) con los resultados del MR5 aplicando MLRA (GPR)

Conclusiones

A continuación, se resumen los resultados más relevantes obtenidos en el presente estudio.

1. La comparación entre Landsat-8 y Sentinel-2 para el cartografiado de los peatlands, mostró que los resultados derivados de Sentinel-2 (con un porcentaje global de correctos de 86,59%) resultaron más precisos frente a los datos obtenidos con L8 (con un porcentaje global de correctos de 77,90%).
2. Para el cartografiado de los humedales altoandinos (andean peatlands) con Sentinel-2 se han comparado tres métodos usando solo los productos automáticos de vegetación, las bandas o varios índices espectrales, observando que el valor más alto del porcentaje global de correctos (98,27%) se obtuvo con el modelo que usa 8 índices de vegetación, siendo SAVI y REDEGE los índices de mayor importancia.
3. Con este método se ha estimado que el área ocupada por los peatlands en la Reserva de Producción de Fauna Chimborazo fue de 23292 ha.
4. Los datos de campo muestran una fuerte correlación entre la biomasa y el contenido en agua de la vegetación de la zona, siendo el contenido en agua 1,6 veces la biomasa, lo que es indicativo de una vegetación muy húmeda.
5. Para la estimación del carbono de la vegetación las variables más importantes fueron, en orden: la elevación, precipitación, la relación VV/VH de Sentinel-1, el índice NBRI y el LAI de Sentinel-2.
6. De los 4 métodos MLRA probados para la estimación del carbono de la vegetación, fue GPR el que obtuvo mejor correlación, con $R^2 = 0,76$, con las variables señaladas antes.

Conclusiones

7. En cuanto a la estimación del carbono de la vegetación usando solo las bandas de Sentinel-2, se ha entrenado un modelo con datos de campo y usando GPR, que ha mostrado que las bandas más relevantes fueron la B5 (Red Edge) y la B8a (NIR).
8. Aplicando este método a las imágenes Sentinel-2 de 2017 y 2020, se ha observado una pérdida de carbono de la vegetación del área en estudio de 71975 Mg en 2017 a 59362 Mg en 2020.
9. Los productos automáticos de vegetación obtenidos por SNAP a partir de Sentinel-2, no han mostrado correlación con los datos de campo, seguramente debido al tipo de vegetación de la zona, mayoritariamente de tipo musgo de menos de 3 cm de altura.
10. Para la estimación del carbono orgánico del suelo las mejores variables por orden de importancia fueron: la elevación, usos de suelo, temperatura, distancia a ríos, REDEEDGE de Sentinel-2 y el band ratio del promedio (VH/VV) de Sentinel-1.
11. De los 4 métodos MLRA probados para la estimación del carbono del suelo, GPR mostró la mejor correlación con $R^2 = 0,76$, y las variables señaladas antes, con lo que se pudo estimar la cantidad de carbono almacenado en suelo en la capa 0-30 cm en 13639407 Mg.

Perspectivas futuras

Dada la importancia del ecosistema peatland dentro de los páramos del Ecuador y a su capacidad de acumulación de carbono por la ubicación y sus condiciones climáticas, es necesario realizar investigaciones adicionales no solo de la dinámica actual del carbono sino también de los efectos de la perturbación antropogénica y su tasa de degradación.

Al ser los peatlands ecosistemas sensibles es necesario estudios a largo plazo (más de cinco años) sobre su restauración. Los métodos desarrollados en esta tesis pueden servir para estudios multitemporales que permitan analizar el cambio en el área ocupada por los bofedales en el RPFCH y la variación en su capacidad de almacenamiento de carbono.

Debido a que los peatlands de estudio se encuentran alrededor de dos nevados, es importante el monitoreo de la cantidad de agua proveniente del glaciar y los páramos aledaños hacia los mismos.

Para mejorar la precisión en las estimaciones del carbono del suelo, es necesario mejorar la información obtenida de capas como usos de suelo y temperatura, lo que puede realizarse con teledetección.

Referencias

Abdelbaki, A., Schlerf, M., Verrelst, J., Udelhoven, T., & Slc, S. (2020). *Using different retrieval methods for evaluating retrieval performance based on UAV-hyperspectral data* (p. 1).

Ahmed, K. R., & Akter, S. (2017). Analysis of landcover change in southwest Bengal delta due to floods by NDVI, NDWI and K-means cluster with landsat multi-spectral surface reflectance satellite data. *Remote Sensing Applications: Society and Environment*, 8(August), 168–181. <https://doi.org/10.1016/j.rsase.2017.08.010>

Andrade, J. (2016). *Determinación del estado de conservación de los bofedales de la Reseva de Producción de Fauna Chimborazo*. Escuela Superior Politécnica de Chimborazo.

Ayala-Izurieta, J. E., Márquez, C. O., García, V. J., Jara-Santillán, C. A., Sisti, J. M., Pasqualotto, N., Van Wittenberghe, S., & Delegido, J. (2021). Multi-predictor mapping of soil organic carbon in the alpine tundra: a case study for the central Ecuadorian paramo. *Carbon Balance and Management*, 2, 1–19. <https://doi.org/10.1186/s13021-021-00195-2>

Ayala-Izurieta, J., Márquez, C., García, V., Recalde, C., Rodríguez, M., & Damián, D. (2017). Land Cover Classification in an Ecuadorian Mountain Geosystem Using a Random Forest Classifier, Spectral Vegetation Indices, and Ancillary Geographic Data. *Geosciences*. <https://doi.org/10.3390/geosciences7020034>

Bazi, Y., Alajlan, N., Melgani, F., AlHichri, H., & Yager, R. R. (2014). Concentrations With Gaussian Process. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(7), 3019–3028.

Benavides, J. C. (2013). Perturbaciones en las turberas de páramo: la acción del hombre y el clima. In J. Cortés-Duque & C. E. Sarmiento (Eds.), *Visión socioecosistémica de los páramos y la alta montaña colombiana: memorias del proceso de definición de criterios para la delimitación de páramos* (pp. 81–87).

Beven, K. J., & Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin*, 24(1), 43–69. <https://doi.org/10.1080/02626667909491834>

Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 123–140.

Referencias

<https://doi.org/10.3390/risks8030083>

Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. <https://doi.org/https://doi.org/10.1023/A:1010933404324>

Byrd, K. B., Ballanti, L., Thomas, N., Nguyen, D., Holmquist, J. R., & Simard, M. (2018). A remote sensing-based model of tidal marsh aboveground carbon stocks for the conterminous United States. *ISPRS Journal of Photogrammetry and Remote Sensing*, 139, 255–271. <https://doi.org/10.1016/j.isprsjprs.2018.03.019>

Caballero, G. R. (2018). Estimación del LAI de la vegetación a partir del la sinergia Sentinel 1 – Sentinel 2. In *Universidad de Valencia* (TFM November). <https://doi.org/10.13140/RG.2.2.22445.95203>

Caballero, G. R., Platzcek, G., Pezzola, A., Casella, A., Winschel, C., Silva, S. S., Ludueña, E., Pasqualotto, N., & Delegido, J. (2020). Assessment of Multi-Date Sentinel-1 Polarizations and GLCM Texture Features Capacity for Onion and Sunflower Classification in an Irrigated Valley: An Object Level Approach. *Agronomy*, 10(6). <https://doi.org/10.3390/agronomy10060845>

Camps-Valls, G., Gómez-Chova, L., Muñoz-Marí, J., Vila-Francés, J., Amorós, J., Del Valle-Tascon, S., & Calpe-Maravilla, J. (2009). Biophysical parameter estimation with adaptive Gaussian processes. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4, 69–72. <https://doi.org/10.1109/IGARSS.2009.5417372>

Camps-Valls, Gustau, Jung, M., Ichii, K., Papale, D., Tramontana, G., Bodesheim, P., Schwalm, C., Zscheischler, J., Mahecha, M., & Reichstein, M. (2015). Ranking drivers of global carbon and energy fluxes over land. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015-Novem, 4416–4419. <https://doi.org/10.1109/IGARSS.2015.7326806>

Castillo, J. A. A., Apan, A. A., Maraseni, T. N., & Salmo, S. G. (2017). Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134, 70–85. <https://doi.org/10.1016/j.isprsjprs.2017.10.016>

Castro Izurieta, D. F. (2016). The Volcano Chimborazo “ The Colossus of the Andes .” *Bionatura*, 1(3), 154–156. <http://www.revistabionatura.com>

Castro, M. (2011). Una valoración económica del almacenamiento de agua y

carbono en los bofedales de los Páramos Ecuatorianos - la experiencia en Oña-Nabón-Saraguro-Yacuambi y el Frente Suroccidental de Tungurahua. *EcoCiencia / Wetlands International / UTPL / MAE*.

Chimner, R. A., Ott, C. A., Perry, C. H., & Kolka, R. K. (2014). Developing and Evaluating Rapid Field Methods to Estimate Peat Carbon. *Wetlands*, 1241–1246. <https://doi.org/10.1007/s13157-014-0574-6>

Comas, X., Terry, N., Hribljan, J. A., Lilleskov, E. A., Suarez, E., Chimner, R. A., & Kolka, R. K. (2017). Estimating belowground carbon stocks in peatlands of the Ecuadorian páramo using ground-penetrating radar (GPR). *Journal of Geophysical Research: Biogeosciences*, 122(2), 370–386. <https://doi.org/10.1002/2016JG003550>

Conant, R. T., & Paustian, K. (2002). Spatial variability of soil organic carbon in grasslands: Implications for detecting change at different scales. *Environmental Pollution*, 116(SUPPL. 1), 127–135. [https://doi.org/10.1016/S0269-7491\(01\)00265-2](https://doi.org/10.1016/S0269-7491(01)00265-2)

Dabrowska-Zielinska, K., Budzynska, M., Tomaszewska, M., Bartold, M., & Gatkowska, M. (2015). The study of multifrequency microwave satellite images for vegetation biomass and humidity of the area under Ramsar convention. *International Geoscience and Remote Sensing Symposium (IGARSS), 2015-Novem*, 5198–5200. <https://doi.org/10.1109/IGARSS.2015.7327005>

Delegido, J., Verrelst, J., Alonso, L., & Moreno, J. (2011). Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063–7081. <https://doi.org/10.3390/s110707063>

Díaz, P. (2015). *Caracterización ecológica de los Bofedales, como hábitat vital de las Vicuñas en la Reserva de Producción de Fauna Chimborazo con la aplicación de herramientas de SIG y teledetección*. Universidad San Francisco de Quito.

Domínguez, E., & Vega-Valdés, D. (2015). Funciones y servicios ecosistémicos de las turberas en Magallanes. Colección de libros INIA N° 33. Instituto de Investigaciones Agropecuarias. Centro Regional de Investigación Kampenaike. In *Colección de libros INIA N° 33*.

Draper, F. C., Roucoux, K. H., & Lawson, I. T. (2014). The distribution and amount of carbon in the largest peatland complex in Amazonia. *Environmental Research Letters*, 12. <https://doi.org/10.1088/1748-9326/9/12/124017>

Referencias

- ESA. (2015). Sentinel-2 User Handbook. *European Space Agency* (pp. 1–64). https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook
- ESA. (2021a). Mission Sentinel-1. *European Space Agency* <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- ESA. (2021b). *Sen2Cor*. <https://step.esa.int/main/snap-supported-plugins/sen2cor/>
- Escuela Superior Politécnica de Chimborazo y Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ). (2018). *Hacia un manejo adaptativo de la Reserva de Producción de Fauna Chimborazo y su zona de amortiguamiento. Sistematización de la aplicación de la metodología Manejo Adaptativo de Riesgo y Vulnerabilidad en Sitios de Conservación (MARISCO)*.
- Estévez, J., Berger, K., Vicent, J., Rivera-Caicedo, J. P., Wocher, M., & Verrelst, J. (2021). Top-of-atmosphere retrieval of multiple crop traits using variational heteroscedastic gaussian processes within a hybrid workflow. *Remote Sensing*, *13*(8), 1–26. <https://doi.org/10.3390/rs13081589>
- Estévez, J., Vicent, J., Rivera-Caicedo, J. P., Morcillo-Pallarés, P., Vuolo, F., Sabater, N., Camps-Valls, G., Moreno, J., & Verrelst, J. (2020). Gaussian processes retrieval of LAI from Sentinel-2 top-of-atmosphere radiance data. *ISPRS Journal of Photogrammetry and Remote Sensing*, *167*(June), 289–304. <https://doi.org/10.1016/j.isprsjprs.2020.07.004>
- Fang, D., Zhang, X., Yu, Q., Jin, T. C., & Tian, L. (2018). A novel method for carbon dioxide emission forecasting based on improved Gaussian processes regression. *Journal of Cleaner Production*, *173*, 143–150. <https://doi.org/10.1016/j.jclepro.2017.05.102>
- Fidalgo, C., Gonzáles, J., Corral, M., García, R., & Arteaga, C. (2020). Peatlands evolution in Central Iberia (Montes de Toledo, Spain) and its link to anthropogenic processes: a cartography-based study. *ESPACIO, TIEMPO Y FORMA*, *13*, 81–102. <https://doi.org/http://dx.doi.org/10.5944/etfvi.13.2020>
- Frey, C. (2017). *Determinación de la cantidad de carbono orgánico almacenado en la flora de los bofedales de la Reserva de Producción de Fauna Chimborazo*. Escuela Superior Politécnica de Chimborazo.
- Gabov, D. N., Beznosikov, V. A., & Yakovleva, E. V. (2017). Accumulation of polycyclic aromatic hydrocarbons in hummocky tundra peatlands under climate change at high latitudes. *Geochemistry International*, *55*(8), 737–751.

<https://doi.org/10.1134/S0016702917060039>

Gitelson, A. A. (2004). Wide Dynamic Range Vegetation Index for Remote Quantification of Biophysical Characteristics of Vegetation. *Journal of Plant Physiology*, 161(2), 165–173. <https://doi.org/10.1078/0176-1617-01176>

Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1–4. <https://doi.org/10.1029/2005GL022688>

Granizo, T., Molina, M. E., Secaira, E., Herrera, B., Benítez, S., Maldonado, Ó., Libby, M., Arroyo, P., Ísola, S., & Castro, M. (2006). *Manual de Planificación para la Conservación de Áreas, PCA* (M. Cuvi (ed.)). TNC y USAID.

Gumbricht, T., Roman-cuesta, R. M., Murdiyarsa, D., Verchot, L., Herold, M., Wittmann, F., Householder, E., & Herold, N. (2017). An expert system model for mapping tropical wetlands and peatlands reveals South America as the largest contributor. *Global Change Biology*, November 2016, 3581–3599. <https://doi.org/10.1111/gcb.13689>

Han, D., Vahedifard, F., & Aanstoos, J. V. (2017). Investigating the correlation between radar backscatter and in situ soil property measurements. *International Journal of Applied Earth Observation and Geoinformation*, 57, 136–144. <https://doi.org/10.1016/j.jag.2016.12.018>

Hribljan, J. A., Suarez, E., Bourgeau-Chavez, L., Endres, S., Lilleskov, E. A., Chimbolema, S., Wayson, C., Serocki, E., & Chimner, R. A. (2017). Multidate, multisensor remote sensing reveals high density of carbon-rich mountain peatlands in the páramo of Ecuador. *Global Change Biology*, 23(12), 5412–5425. <https://doi.org/10.1111/gcb.13807>

Hribljan, J. A., Suárez, E., Heckman, K. A., Lilleskov, E. A., & Chimner, R. A. (2016). Peatland carbon stocks and accumulation rates in the Ecuadorian páramo. *Wetlands Ecology and Management*, 24(2), 113–127. <https://doi.org/10.1007/s11273-016-9482-2>

Inhami. (2019). *Instituto Nacional de Meteorología e Hidrología*. Ecuador

Iturraspe, R. (2010). Las turberas de Tierra del Fuego y el Cambio Climático global. In *Fundación Humedales / Wetlands International* (Issue January 2010). <http://www.wetlands.org/LinkClick.aspx?fileticket=racaH0t+CLw=&tabid=56>

Referencias

- IUCN. (2015). *Land Degradation Neutrality: implications and opportunities for conservation* (Issue November, p. 19).
- Jara, C., Delegido, J., Ayala, J., Lozano, P., Armas, A., & Flores, V. (2019). Estudio de bofedales en los Andes ecuatorianos a través de la comparación de imágenes Landsat-8 y Sentinel-2. *Revista de Teledetección*, 53, 45. <https://doi.org/10.4995/raet.2019.11715>
- Jensen, D., Cavanaugh, K. C., Simard, M., Okin, G. S., Castañeda-Moya, E., McCall, A., & Twilley, R. R. (2019). Integrating imaging spectrometer and synthetic aperture radar data for estimating wetland vegetation aboveground biomass in coastal Louisiana. *Remote Sensing*, 11(21). <https://doi.org/10.3390/rs11212533>
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jin, X., Li, Z., Feng, H., Ren, Z., & Li, S. (2020). Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index. *The Crop Journal*, 8(1), 87–97. <https://doi.org/10.1016/j.cj.2019.06.005>
- Kamenova, I., & Dimitrov, P. (2021). Evaluation of Sentinel-2 vegetation indices for prediction of LAI, fAPAR and fCover of winter wheat in Bulgaria. *European Journal of Remote Sensing*, 54(sup1), 89–108. <https://doi.org/10.1080/22797254.2020.1839359>
- Key, C. H., & Benson, N. C. (2006). Landscape Assessment (LA) sampling and analysis methods. *USDA Forest Service - General Technical Report RMRS-GTR, 164 RMRS-GTR*.
- Klarqvist, M. (2001). *Peat growth and carbon accumulation rates during the holocene in boreal mires, Doctor's dissertation*.
- Köchy, M., Hiederer, R., & Freibauer, A. (2015). *Global distribution of soil organic carbon – Part 1: Masses and frequency distributions of SOC stocks for the tropics, permafrost regions, wetlands, and the world*. 351–365. <https://doi.org/10.5194/soil-1-351-2015>
- Lal, R. (2005). Forest soils and carbon sequestration. *Forest Ecology and Management*, 220(1–3), 242–258. <https://doi.org/10.1016/j.foreco.2005.08.015>

- Lamichhane, S., Kumar, L., & Wilson, B. (2019). Geoderma Digital soil mapping algorithms and covariates for soil organic carbon mapping and their implications : A review. *Geoderma*, 352(June), 395–413. <https://doi.org/10.1016/j.geoderma.2019.05.031>
- Lawson, I. T., Kelly, T. J., Aplin, P., Boom, A., Dargie, G., Draper, F. C. H., Hassan, P. N. Z. B. P., Hoyos-Santillan, J., Kaduk, J., Large, D., Murphy, W., Page, S. E., Roucoux, K. H., Sjögersten, S., Tansey, K., Waldram, M., Wedeux, B. M. M., & Wheeler, J. (2015). Improving estimates of tropical peatland area, carbon storage, and greenhouse gas fluxes. *Wetlands Ecology and Management*, 23(3), 327–346. <https://doi.org/10.1007/s11273-014-9402-2>
- Lázaro-Gredilla, M., & Titsias, M. K. (2011). Variational heteroscedastic Gaussian process regression. *Proceedings of the 28th International Conference on Machine Learning, ICML 2011*, 841–848.
- Lázaro-Gredilla, M., Titsias, M. K., Verrelst, J., & Camps-Valls, G. (2014). Retrieval of biophysical parameters with heteroscedastic Gaussian processes. *IEEE Geoscience and Remote Sensing Letters*, 11(4), 838–842. <https://doi.org/10.1109/LGRS.2013.2279695>
- Lees, K. J., Quaife, T., Artz, R. R. E., Khomik, M., & Clark, J. M. (2018). Potential for using remote sensing to estimate carbon fluxes across northern peatlands – A review. *Science of the Total Environment*, 615, 857–874. <https://doi.org/10.1016/j.scitotenv.2017.09.103>
- León, Y., & Reyes, J. (2018). Delimitación y descripción biofísica de dos turberas y de una laguna endorreica en el sector Salsipuedes-Cerro Asunción, Parque Nacional Tapantí - Macizo de la Muerte, Costa Rica. *UNED Research Journal*, 10(1), 221–226. <https://doi.org/10.22458/urj.v10i1.2030>
- Liu, J., Feng, Q., Gong, J., Zhou, J., & Li, Y. (2016). Land-cover classification of the Yellow River Delta wetland based on multiple end-member spectral mixture analysis and a Random Forest classifier. *International Journal of Remote Sensing*, 37(8), 1845–1867. <https://doi.org/10.1080/01431161.2016.1165888>
- Liu, K., Ding, H., Tang, G., Zhu, A. X., Yang, X., Jiang, S., & Cao, J. (2017). An object-based approach for two-level gully feature mapping using high-resolution DEM and imagery: a case study on hilly loess plateau region, China. *Chinese Geographical Science*, 27(3), 415–430. <https://doi.org/10.1007/s11769-017-0874-x>

Referencias

- Lozano, P. (2017). *Valoración económica del carbono capturado en el suelo de los bofedales de la Reserva de Producción de Fauna Chimborazo*. Escuela Superior Politécnica de Chimborazo.
- Machado, G., Mendoza, M. R., & Corbellini, L. G. (2015). What variables are important in predicting bovine viral diarrhoea virus? A random forest approach. *Veterinary Research*, *46*(1), 1–15. <https://doi.org/10.1186/s13567-015-0219-7>
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Brisco, B., Mahdavi, S., Amani, M., & Granger, J. E. (2018). Fisher Linear Discriminant Analysis of coherency matrix for wetland classification using PolSAR imagery. *Remote Sensing of Environment*, *206*(January), 300–317. <https://doi.org/10.1016/j.rse.2017.11.005>
- Martinez-Cortizas, A., Chesworth, W., & García-Rodeja, E. (2001). Dinámica geoquímica de las turberas de Galicia. In *Turberas de montaña de Galicia*.
- McFEETERS, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, *17*(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Millard, K., & Richardson, M. (2015). On the importance of training data sample selection in Random Forest image classification: A case study in peatland ecosystem mapping. *Remote Sensing*, *7*(7), 8489–8515. <https://doi.org/10.3390/rs70708489>
- Minasny, B., Berglund, Ö., Connolly, J., Hedley, C., de Vries, F., Gimona, A., Kempen, B., Kidd, D., Lilja, H., Malone, B., McBratney, A., Roudier, P., O'Rourke, S., Rudianto, Padarian, J., Poggio, L., ten Caten, A., Thompson, D., Tuve, C., & Widyatmanti, W. (2019). Digital mapping of peatlands – A critical review. *Earth-Science Reviews*, *196*(May), 102870. <https://doi.org/10.1016/j.earscirev.2019.05.014>
- Minayeva, T. Y., & Sirin, A. A. (2012). Peatland biodiversity and climate change. *Biology Bulletin Reviews*, *2*(2), 164–175. <https://doi.org/10.1134/s207908641202003x>
- Ministerio del Ambiente. (2014). *Actualización Del Plan de Manejo de La Reserva de Producción de Funa Chimborazo*.
- Morley, P. J., Donoghue, D. N. M., Chen, J., & Jump, A. S. (2019). Quantifying structural diversity to better estimate change at mountain forest margins. *Remote*

Sensing of Environment, 223(February), 291–306.
<https://doi.org/10.1016/j.rse.2019.01.027>

Musotto, L. (2013). *Paleoambientes y paleoclimas del Cuaternario tardío en turberas del centro de la Isla Grande de Tierra del Fuego en base al análisis palinológico*, Tesis Doctoral. UNIVERSIDAD NACIONAL DEL SUR.

Musotto, L. L., Candel, M. S., Borromei, A. M., Ponce, J. F., & Bianchinotti, M. V. (2018). La palinología como una herramienta para la caracterización de paleoambientes continentales y marinos del Cuaternario tardío en el Archipiélago de Tierra del Fuego. *Publicación Electrónica de La Asociación Paleontológica Argentina*, 10(2), 131–155.
<https://doi.org/http://dx.doi.org/10.5710/PEAPA.16.05.2018.248>

Nadle, C., Meza, A., Torres, R., & Jara, M. A. (2001). Medición del carbono almacenado en los bosques de la Reserva Nacional Malleco. XI Region, Chile. *Simposio Internacional Medición y Monitoreo de La Captura de Carbono En Ecosistemas Forestales 18 Al 20 de Octubre Del 2001 Valdivia - Chile*, 1–13.

Naidoo, L., Deventer, H. Van, Ramoelo, A., Mathieu, R., & Nondlazi, B. (2019). Estimating above ground biomass as an indicator of carbon storage in vegetated wetlands of the grassland biome of South Africa. *Int J Appl Earth Obs Geoinformation*, 78(February), 118–129. <https://doi.org/10.1016/j.jag.2019.01.021>

Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with random forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34(1), 136–146. <https://doi.org/10.1016/j.jag.2014.08.001>

Okujeni, A., van der Linden, S., Jakimow, B., Rabe, A., Verrelst, J., & Hostert, P. (2014). A comparison of advanced regression algorithms for quantifying urban land cover. *Remote Sensing*, 6(7), 6324–6346. <https://doi.org/10.3390/rs6076324>

Peppo, M. De, Taramelli, A., Boschetti, M., Mantino, A., Volpi, I., Filipponi, F., Tornato, A., Valentini, E., & Ragaglini, G. (2021). Non-Parametric Statistical Approaches for Leaf Area Index Estimation from Sentinel-2 Data : A Multi-Crop Assessment. *Remote Sensing*, April.

Pérez-Planells, L., Delegido, J., Rivera-Caicedo, J. P., & Verrelst, J. (2015). Análisis de métodos de validación cruzada para la obtención robusta de parámetros biofísicos. *Revista de Teledeteccion*, 2015(44), 55–65.
<https://doi.org/10.4995/raet.2015.4153>

Referencias

- Pittman, R., Hu, B., & Webster, K. (2021). Improvement of soil property mapping in the Great Clay Belt of northern Ontario using multi-source remotely sensed data. *Geoderma*, 381(April 2020). <https://doi.org/10.1016/j.geoderma.2020.114761>
- Podest, E. (2021). *Conceptos Básicos del Radar de Apertura Sintética*. <https://appliedsciences.nasa.gov/sites/default/files/Session1-SAR-Spanish.pdf>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Ramsar. (2013). The Ramsar Convention Manual , 6th edition. In *The Ramsar Convention Manual: a guide to the Convention on Wetlands (Ramsar, Iran, 1971)* (6th editio). <http://www.ramsar.org/sites/default/files/documents/library/manual6-2013-e.pdf>
- Ramsar. (2021). *The List of Wetlands of International Importance*. <https://www.ramsar.org/sites/default/files/documents/library/sitelist.pdf>
- Rasmussen, C. E., & Williams, C. K. I. (2006). Gaussian Processes for Machine Learning. In *The MIT Press*. www.GaussianProcess.org/gpml
- Rial, M., Martínez Cortizas, A., Taboada, T., & Rodríguez-Lado, L. (2017). Soil organic carbon stocks in Santa Cruz Island, Galapagos, under different climate change scenarios. *Catena*, 156(May), 74–81. <https://doi.org/10.1016/j.catena.2017.03.020>
- Rivas, J., & Vega, M. (2018). Ecuador Complejo de Humedales Cuyabeno Lagartococha Yasuní. In *Ficha Informativa RAMSAR*. <https://rsis.ramsar.org/ris/2332>
- Rivera, J. P., Verrelst, J., Delegido, J., & Moreno, J. (2011). Herramienta informática para el diseño y evaluación de índices espectrales genéricos para inversión de parámetros biofísicos. *SELPER, Medellín, Colombia. 29 de Septiembre al 3 de Octubre de 2014*
- Rodríguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sánchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(1), 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>

- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1986). Monitoring Vegetation Systems in the Great Plains with ERTS. In *Third Earth Resources Technology Satellite (ERTS) Symposium* (Vol. 1, pp. 309–317).
- Rudiyanto, B., Minasny, B., Indra, B., Krido, S., & McBratney, A. (2018). Open digital mapping as a cost-effective method for mapping peat thickness and assessing the carbon stock of tropical peatlands. *Geoderma*, *313*(August 2017), 25–40. <https://doi.org/10.1016/j.geoderma.2017.10.018>
- Rudiyanto, B., Minasny, B., Setiawan, B. I., Arif, C., Saptomo, S. K., & Chadirin, Y. (2016). Digital mapping for cost-effective and accurate prediction of the depth and carbon stocks in Indonesian peatlands. *Geoderma*, *272*, 20–31. <https://doi.org/10.1016/j.geoderma.2016.02.026>
- Rügnitz, M., Chacón, M., & Porro, R. (2009). *Guía para la Determinación de Carbono en Pequeñas Propiedades Rurales* (Primera). Centro Mundial Agroflorestral (ICRAF) / Consórcio Iniciativa Amazônica (IA)
- Shen, X., Foster, T., Baldi, H., Dobreva, I., Burson, B., Hays, D., Tabien, R., & Jessup, R. (2019). Quantification of soil organic carbon in biochar-amended soil using ground penetrating radar (GPR). *Remote Sensing*, *11*(23), 1–12. <https://doi.org/10.3390/rs11232874>
- SNI. (2014). *Sistema Nacional de Información. Archivos de información Geográfica*. <https://sni.gob.ec/coberturas>
- Sørensen, R., Zinko, U., & Seibert, J. (2006). On the calculation of the topographic wetness index: Evaluation of different methods based on field observations. *Hydrology and Earth System Sciences*, *10*(1), 101–112. <https://doi.org/10.5194/hess-10-101-2006>
- Thomas, N., Simard, M., Castañeda-Moya, E., Byrd, K., Windham-Myers, L., Bevington, A., & Twilley, R. R. (2019). High-resolution mapping of biomass and distribution of marsh and forested wetlands in southeastern coastal Louisiana. *International Journal of Applied Earth Observation and Geoinformation*, *80*(December 2018), 257–267. <https://doi.org/10.1016/j.jag.2019.03.013>
- Torbick, N., & Salas, W. (2015). Mapping agricultural wetlands in the Sacramento Valley, USA with satellite remote sensing. *Wetlands Ecology and Management*, *23*(1), 79–94. <https://doi.org/10.1007/s11273-014-9342-x>
- Turunen, J., Tomppo, E., Tolonen, K., & Reinikainen, A. (2002). Estimating carbon

Referencias

accumulation rates of undrained mires in Finland – application to boreal and subarctic regions. *The Holocene*, *1*, 69–80. <https://doi.org/https://doi.org/10.1191/0959683602hl522rp>

Upreti, D., Huang, W., Kong, W., Pascucci, S., Pignatti, S., Zhou, X., Ye, H., & Casa, R. (2019). A comparison of hybrid machine learning algorithms for the retrieval of wheat biophysical variables from sentinel-2. *Remote Sensing*, *11*(5). <https://doi.org/10.3390/rs11050481>

Van Wittenberghe, S., Verrelst, J., Rivera, J. P., Alonso, L., Moreno, J., & Samson, R. (2014). Gaussian processes retrieval of leaf parameters from a multi-species reflectance, absorbance and fluorescence dataset. *Journal of Photochemistry and Photobiology B: Biology*, *134*(2014), 37–48. <https://doi.org/10.1016/j.jphotobiol.2014.03.010>

Verrelst, J., & Rivera, J. P. (2021a). *ARTMO v. 3.29 Manual* (pp. 1–52). <https://artmtoolbox.com/>

Verrelst, J., & Rivera, J. P. (2021b). *MLRA toolbox v1.26 Manual* (pp. 1–72). <https://artmtoolbox.com/>

Verrelst, J., Alonso, L., Camps-Valls, G., Delegido, J., & Moreno, J. (2012). Retrieval of vegetation biophysical parameters using Gaussian process techniques. *IEEE Transactions on Geoscience and Remote Sensing*, *50*(5 PART 2), 1832–1843. <https://doi.org/10.1109/TGRS.2011.2168962>

Verrelst, J., Alonso, L., Pablo, J., Caicedo, R., Moreno, J., Camps-valls, G., & Member, S. (2013). Gaussian Process Retrieval of Chlorophyll Content From Imaging Spectroscopy Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *6*(2), 1–8.

Verrelst, J., Berger, K., & Rivera-Caicedo, J. P. (2020). Intelligent Sampling for Vegetation Nitrogen Mapping Based on Hybrid Machine Learning Algorithms. *IEEE Geoscience and Remote Sensing Letters*, 1–5. <https://doi.org/10.1109/lgrs.2020.3014676>

Verrelst, J., Rivera, J. P., Moreno, J., & Camps-Valls, G. (2013). Gaussian processes uncertainty estimates in experimental Sentinel-2 LAI and leaf chlorophyll content retrieval. *ISPRS Journal of Photogrammetry and Remote Sensing*, *86*, 157–167. <https://doi.org/10.1016/j.isprsjprs.2013.09.012>

Verrelst, J., Romijn, E., & Kooistra, L. (2012). Mapping vegetation density in a

- heterogeneous river floodplain ecosystem using pointable CHRIS/PROBA data. *Remote Sensing*, 4(9), 2866–2889. <https://doi.org/10.3390/rs4092866>
- Viscarra, R. A., McKenzie, N. J., & Grundy, M. J. (2010). Using Proximal Soil Sensors for Digital Soil Mapping. In *Digital Soil Mapping* (pp. 79–92). Springer. https://doi.org/https://doi.org/10.1007/978-90-481-8863-5_6
- Vistin-Guamantaqui, D., Muñoz, E., & Ati, G. (2021). CLIMATE CHANGE SCENARIO OF EVERGREEN FOREST OF THE MOORLAND CHIMBORAZO FAUNA PRODUCTION RESERVE- ECUADOR. *Tropical and Subtropical Agroecosystems*, 24(56), 13.
- Wang, B., Waters, C., Orgill, S., Gray, J., Cowie, A., Clark, A., & Liu, D. L. (2018). High resolution mapping of soil organic carbon stocks using remote sensing variables in the semi-arid rangelands of eastern Australia. *Science of the Total Environment*, 630, 367–378. <https://doi.org/10.1016/j.scitotenv.2018.02.204>
- Wang, F., Huang, J., Tang, Y., & Wang, X. (2007). New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. *Rice Science*, 14(3), 195–203. [https://doi.org/10.1016/S1672-6308\(07\)60027-4](https://doi.org/10.1016/S1672-6308(07)60027-4)
- Wang, J., Xiao, X., Bajgain, R., Starks, P., Steiner, J., & Doughty, R. B. (2019). Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154(June), 189–201. <https://doi.org/10.1016/j.isprsjprs.2019.06.007>
- Wang, Q., Shi, W., Li, Z., & Atkinson, P. M. (2016). Fusion of Sentinel-2 images. *Remote Sensing of Environment*, 187, 241–252. <https://doi.org/10.1016/j.rse.2016.10.030>
- Wang, Y., Deng, L., Wu, G., Wang, K., & Shangguan, Z. (2018). Large-scale soil organic carbon mapping based on multivariate modelling: The case of grasslands on the Loess Plateau Yinyin. *Land Degrad Dev.*, 29, 26–37. <https://doi.org/10.1002/ldr.2833>
- Weiss, M., & Baret, F. (2016). *S2ToolBox Level 2 products*. https://step.esa.int/docs/extra/ATBD_S2ToolBox_L2B_V1.1.pdf
- White, L., Millard, K., Banks, S., Richardson, M., Pasher, J., & Duffe, J. (2017). Moving to the RADARSAT constellation mission: Comparing synthesized compact polarimetry and dual polarimetry data with fully polarimetric

Referencias

RADARSAT-2 data for image classification of peatlands. *Remote Sensing*, 9(6), 1–29. <https://doi.org/10.3390/rs9060573>

Xie, Q., Dash, J., Huete, A., Jiang, A., Yin, G., Ding, Y., Peng, D., Hall, C. C., Brown, L., Shi, Y., Ye, H., Dong, Y., & Huang, W. (2019). Retrieval of crop biophysical parameters from Sentinel-2 remote sensing imagery. *International Journal of Applied Earth Observation and Geoinformation*, 80(January), 187–195. <https://doi.org/10.1016/j.jag.2019.04.019>

Yang, R. M., & Guo, W.-W. (2019). Modelling of soil organic carbon and bulk density in invaded coastal wetlands using Sentinel-1 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 82(June), 101906. <https://doi.org/10.1016/j.jag.2019.101906>

Yang, R. M., Guo, W. W., & Zheng, J. B. (2019). Soil prediction for coastal wetlands following *Spartina alterniflora* invasion using Sentinel-1 imagery and structural equation modeling. *Catena*, 173(October 2018), 465–470. <https://doi.org/10.1016/j.catena.2018.10.045>

Yang, R. M., Zhang, G. L., Liu, F., Lu, Y. Y., Yang, F., Yang, F., Yang, M., Zhao, Y. G., & Li, D. C. (2016). Comparison of boosted regression tree and random forest models for mapping topsoil organic carbon concentration in an alpine ecosystem. *Ecological Indicators*, 60, 870–878. <https://doi.org/10.1016/j.ecolind.2015.08.036>

Yang, R., Rossiter, D. G., Liu, F., Lu, Y., Yang, F., Yang, F., Zhao, Y., Li, D., & Zhang, G. (2015). Predictive mapping of topsoil organic Carbon in an Alpine environment aided by Landsat TM. *PLoS ONE*, 10(10), 1–20. <https://doi.org/10.1371/journal.pone.0139042>

Yesou, H., Pottier, E., Mercier, G., Grizonnet, M., Haouet, S., Giros, A., Faivre, R., Huber, C., & Michel, J. (2016). Synergy of Sentinel-1 and Sentinel-2 imagery for wetland monitoring information extraction from continuous flow of sentinel images applied to water bodies and vegetation mapping and monitoring. *International Geoscience and Remote Sensing Symposium (IGARSS), 2016-Novem*, 162–165. <https://doi.org/10.1109/IGARSS.2016.7729033>

Yu, H., Wang, Z., Rezaee, R., Zhang, Y., Xiao, L., Luo, X., Wang, X., & Zhang, L. (2016). The Gaussian Process Regression for TOC Estimation Using Wireline Logs in Shale Gas Reservoirs. *International Petroleum Technology Conference, 14-16 November, Bangkok, Thailand*, 3–5. <https://doi.org/10.2523/iptc-18636-ms>

Yu, Z. C. (2012). *Northern peatland carbon stocks and dynamics : a review*. 4071–138

4085. <https://doi.org/10.5194/bg-9-4071-2012>

Zhou, T., Geng, Y., Chen, J., Liu, M., Haase, D., & Lausch, A. (2020). Mapping soil organic carbon content using multi-source remote sensing variables in the Heihe River Basin in China. *Ecological Indicators*, *114*(March), 106288. <https://doi.org/10.1016/j.ecolind.2020.106288>