

# **ESCUELA POLITÉCNICA NACIONAL**

**FACULTAD DE INGENIERÍA CIVIL Y AMBIENTAL**

**ANÁLISIS PROBABILÍSTICO DE LA VARIABILIDAD ESPACIO-  
TEMPORAL DEL HUMEDAL PUGLLOHUMA UTILIZANDO  
IMÁGENES RADAR DE APERTURA SINTÉTICA DE LA MISIÓN  
SENTINEL - 1**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE  
INGENIERÍA AMBIENTAL**

**PAUL DAVID CARCHIPULLA MORALES**

paul.carchipulla@epn.edu.ec

**Director: Ph.D. XAVIER EDUARDO ZAPATA RÍOS**

xavier.zapata@epn.edu.ec

**Quito, Octubre 2020**

## **DECLARACIÓN**

Yo, Paul David Carchipulla Morales, declaro bajo juramento que el trabajo aquí descrito es de autoría propia; que no ha sido previamente presentada para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Escuela Politécnica Nacional puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.

---

PAUL DAVID CARCHIPULLA MORALES

## **CERTIFICACIÓN**

Como director del trabajo de titulación Análisis probabilístico de la variabilidad espacio-temporal del humedal Pugllohuma utilizando imágenes Radar de Apertura Sintética de la Misión Sentinel - 1 desarrollado por Paul David Carchipulla Morales, estudiante de la carrera de Ingeniería Ambiental, habiendo supervisado la realización de este trabajo y realizado las correcciones correspondientes, doy por aprobada la redacción final del documento escrito para que prosiga con los trámites correspondientes a la sustentación de la Defensa oral.

---

Ph.D. XAVIER EDUARDO ZAPATA RÍOS

## **AUSPICIO**

El presente trabajo de titulación contó con el auspicio financiero del proyecto PIJ-17-05 “Los patrones climáticos globales y su influencia en la respuesta temporal y espacial de índices espectrales de la vegetación del páramo en el Ecuador”, que se ejecutó en el Departamento de Ingeniería Civil y Ambiental.



## AGRADECIMIENTO

Agradezco a mi familia por haberme formado durante todos estos años. También les agradezco por todo el cuidado que han tenido en mí. Sin duda alguna, el hecho de que en la actualidad pueda presentar este trabajo es por toda la dedicación que tuvieron en mí. Espero que mis actos demuestren toda la gratitud que tengo ante mi madre, mi padre, Santiago, Diana, Ricardo, y Michael.

A mi director, Ph.D. Xavier Zapata Ríos, quien me dio la oportunidad de demostrar mis aptitudes. Su guía y enseñanza me han mostrado el tipo de profesional que quiero ser. Su trabajo me ha permitido conocer a excelentes profesionales y seres humanos, entre ellos: Sandra Torres, Carmen Elena López, Paola Fuentes, Bert de Bievre, Sebastián Páez, Jacquelin Montoya, Alex Villarreal, y más personas que me brindaron su ayuda durante el desarrollo del presente proyecto.

También hubo personas que me brindaron su amistad todos estos años. Abigail, Kleber, Jeff, Andrés, y María Inés, ustedes hicieron que los años universitarios fueran más alegres de lo que uno se podría imaginar. Camila y Leo, quienes me acompañaron en tantas noches de dedicación a la ciencia. Ángel Ramírez, quien me permitió cumplir una de mis metas profesionales.

Quiero agradecer a la Escuela Politécnica Nacional por el financiamiento del proyecto PIJ-17-05 “Los patrones climáticos globales y su influencia en la respuesta temporal y espacial de índices espectrales de la vegetación del páramo en el Ecuador”. Este trabajo de titulación se desarrolló en el marco de este proyecto. Además, agradezco por el estipendio brindado durante los meses de abril 2019 a marzo 2020 cuando fui asistente de investigación del mismo.

## **DEDICATORIA**

Dedico el siguiente proyecto de investigación a las ciencias ambientales.

Espero que el presente proyecto tenga un aporte a los conocimientos actuales sobre la teledetección de humedales en la región andina.

Paul David Carchipulla Morales

## CONTENIDO

<b>DECLARACIÓN</b> .....	I
<b>CERTIFICACIÓN</b> .....	II
<b>AUSPICIO</b> .....	III
<b>AGRADECIMIENTO</b> .....	IV
<b>DEDICATORIA</b> .....	V
<b>CONTENIDO</b> .....	VI
<b>ÍNDICE DE TABLAS</b> .....	IX
<b>ÍNDICE DE FIGURAS</b> .....	X
<b>LISTA DE ACRÓNIMOS</b> .....	XII
<b>RESUMEN</b> .....	XIII
<b>ABSTRACT</b> .....	XIV
<b>PRESENTACIÓN</b> .....	XV
<b>CAPÍTULO 1. Introducción</b> .....	1
1.1. Antecedentes .....	1
1.2. Objetivos .....	2
1.2.1. Objetivo general .....	2
1.2.2. Objetivos específicos .....	2
1.3. Alcance .....	2
1.4. Justificación.....	3
<b>CAPÍTULO 2. Estado del arte</b> .....	5
<b>CAPÍTULO 3. Marco teórico</b> .....	7
3.1. Humedales .....	7
3.1.1. Destrucción de los humedales .....	9
3.1.2. Protección de los humedales .....	10
3.2. Humedales altoandinos.....	11
3.3. Servicios ecosistémicos de los humedales altoandinos .....	12

3.4.	Teledetección de humedales.....	14
3.5.	Radars de apertura sintética en mapeo de humedales .....	18
3.6.	Sentinel-1 .....	21
3.6.1.	Longitud de onda .....	24
3.6.2.	Polarización.....	25
3.6.3.	Ángulo de incidencia .....	26
3.6.4.	Temporalidad .....	27
3.7.	Machine learning .....	28
3.7.1.	Random Forest (RF) .....	29
3.7.2.	K-means.....	30
CAPÍTULO 4. Área de estudio .....		31
4.1.	Uso de suelo .....	32
4.2.	Suelo .....	33
4.3.	Cuenca hidrográfica .....	34
4.4.	Variables climáticas en el humedal Pugllohuma .....	35
4.5.	Conductividad hidráulica .....	37
CAPÍTULO 5. Metodología .....		38
5.1.	Recopilación de información .....	38
5.1.1.	Información de monitoreo del humedal Pugllohuma .....	38
5.1.2.	Imágenes satelitales .....	39
5.1.3.	Variables climáticas .....	41
5.2.	Relación entre la saturación del suelo y la retrodispersión del radar	43
5.3.	Clasificación supervisada .....	44
5.3.1.	Muestreo de la clasificación supervisada temporal .....	47
5.3.2.	Construcción y entrenamiento de la clasificación supervisada temporal	48
5.3.3.	Evaluación de la clasificación supervisada temporal .....	50

5.3.4.	Muestreo de la clasificación supervisada ESPACIAL .....	50
5.3.5.	Construcción y entrenamiento de la clasificación supervisada espacial	52
5.3.6.	Evaluación de la clasificación supervisada espacial .....	53
CAPÍTULO 6. Resultados y discusión .....		55
6.1.	Periodos de Saturación .....	55
6.2.	Gráficas de representatividad de variables temporales.....	58
6.3.	Gráficas de representatividad de variables espaciales .....	60
6.4.	Scripts y árbol de decisión de clasificación temporal .....	63
6.5.	Scripts y árbol de decisión de clasificación espacial .....	65
6.6.	Clasificación espacio-temporal del humedal .....	65
6.7.	Evaluación del modelo temporal .....	68
6.8.	Evaluación del modelo espacial .....	69
6.9.	Discusión.....	74
CAPÍTULO 7. Conclusiones y recomendaciones .....		79
7.1.	Conclusiones.....	79
7.2.	Recomendaciones.....	81
REFERENCIAS.....		83
ANEXOS .....		94
ANEXO 1	Registro histórico de variables climáticas .....	95
ANEXO 2	Script de muestreo temporal.....	100
ANEXO 3	Script de clasificación y evaluación temporal.....	112
ANEXO 4	Script de muestreo espacial en GEE .....	116
ANEXO 5	Script de muestreo espacial en R Studio .....	123
ANEXO 6	Script de clasificación espacial .....	127
ANEXO 7	Script de evaluación espacial .....	136
ANEXO 8	Registro fotográfico del humedal Pugllohuma .....	143

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> <i>Ejemplos de humedales en el mundo.</i> .....	7
<b>Tabla 2.</b> <i>Servicios ecosistémicos de humedales altoandinos.</i> .....	14
<b>Tabla 3.</b> <i>Características de los sensores remotos.</i> .....	15
<b>Tabla 4.</b> <i>Número de publicaciones utilizando sensores remotos en investigaciones de humedales de 1964 a 2013.</i> .....	16
<b>Tabla 5.</b> <i>Características de los modos de captura S1.</i> .....	22
<b>Tabla 6.</b> <i>Longitudes de onda de radares satelitales.</i> .....	24
<b>Tabla 7.</b> <i>Ecuaciones de clasificación en Random Forest.</i> .....	30
<b>Tabla 8.</b> <i>Imágenes S1 en Google Earth Engine.</i> .....	40
<b>Tabla 9.</b> <i>Imágenes S2 en Google Earth Engine.</i> .....	40
<b>Tabla 10.</b> <i>Índices polarizados calculados para las imágenes S1.</i> .....	44
<b>Tabla 11.</b> <i>Modelo de la matriz de muestras para la clasificación supervisada temporal.</i> .....	48
<b>Tabla 12.</b> <i>Símbolos asignados a variables del modelo temporal.</i> .....	48
<b>Tabla 13.</b> <i>Modelo de la matriz de muestras para la clasificación supervisada espacial.</i> .....	52
<b>Tabla 14.</b> <i>Símbolos asignados a variables del modelo espacial.</i> .....	53
<b>Tabla 15.</b> <i>Índices espectrales calculados para las imágenes S2.</i> .....	54
<b>Tabla 16.</b> <i>Muestra de S1 para validación.</i> .....	73
<b>Tabla 17.</b> <i>Muestra de S2 para validación.</i> .....	73

## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Campos implicados en el mapeo de humedales con radar. ....	5
<b>Figura 2.</b> Distribución global de lagos, reservorios y humedales. ....	11
<b>Figura 3.</b> Servicios ecosistémicos y bienestar humano. ....	13
<b>Figura 4.</b> Modo operacional de sensores remotos. ....	15
<b>Figura 5.</b> Distribución y cambios en el agua superficial global. ....	18
<b>Figura 6.</b> Distorsiones en una imagen radar. ....	19
<b>Figura 7.</b> Modos de captura de imágenes radar S1. ....	22
<b>Figura 8.</b> Niveles de procesamiento de imágenes S1. ....	24
<b>Figura 9.</b> Efecto de la polarización en objetos. ....	25
<b>Figura 10.</b> Efecto del ángulo de polarización en objetos. ....	27
<b>Figura 11.</b> Información cartográfica del humedal Pugllohuma. Figura a) Ubicación de la cuenca Antisana a nivel de país. Figura b) Modelo digital de terreno de la cuenca Antisana. Figura c) Ubicación e información del humedal Pugllohuma. ..	32
<b>Figura 12.</b> Perfil de suelo en el humedal Pugllohuma: (a) 0-50 cm; (b) 0.5-1 m; (c) 1-1.5; (d) 1.5-2 m; (e) 2-2.5 m; (f) 2.5-3 m; (g) 3-3.5m. ....	33
<b>Figura 13.</b> Información cartográfica de la cuenca Antisana. Figura a) Modelo digital de pendientes de la cuenca Antisana y el humedal Pugllohuma. Figura b) Modelo digital de terreno de la cuenca Antisana y el humedal Pugllohuma. ....	34
<b>Figura 14.</b> Promedio mensual de precipitación y temperatura en el humedal. ....	36
<b>Figura 15.</b> Promedio mensual de presión y humedad relativa en el humedal. ....	36
<b>Figura 16.</b> Promedio mensual de dirección y velocidad del viento en el humedal. ....	37
<b>Figura 17.</b> Captura aérea del humedal Pugllohuma. ....	38
<b>Figura 18.</b> Pozo de control freático. ....	39
<b>Figura 19.</b> Estaciones meteorológicas cerca del humedal Pugllohuma. ....	42
<b>Figura 20.</b> Clasificación espacio-temporal del humedal Pugllohuma. ....	46
<b>Figura 21.</b> Muestreo espacial para clasificación supervisada. Figura a) Áreas de muestra en el periodo seco. Figura b) Áreas de muestra en el periodo húmedo. ....	51
<b>Figura 22.</b> Distribución temporal del nivel freático en el humedal. ....	55
<b>Figura 23.</b> Ponderación de datos climáticos en el humedal de 2016 a 2020. ....	56
<b>Figura 24.</b> Ponderación mensual de viento en el humedal de 2016 a 2020. ....	57

<b>Figura 25.</b> Correlación de variables de clasificación temporal.....	58
<b>Figura 26.</b> Curva OOB vs árboles de decisión en clasificación temporal. ....	59
<b>Figura 27.</b> Importancia e impurezas de variables en clasificación temporal.....	60
<b>Figura 28.</b> Correlación de variables en clasificación espacial.....	61
<b>Figura 29.</b> Nueva correlación de variables en clasificación espacial.....	62
<b>Figura 30.</b> Importancia e impurezas de variables en clasificación espacial.....	63
<b>Figura 31.</b> Árbol de decisión en clasificación temporal.....	64
<b>Figura 32.</b> Evolución de la clasificación espacio-temporal del suelo seco.....	66
<b>Figura 33.</b> Evolución de la clasificación espacio-temporal del suelo húmedo. ....	67
<b>Figura 34.</b> Evolución de la clasificación espacio-temporal del suelo cerca de la saturación.....	68
<b>Figura 35.</b> Evaluación de la probabilidad en clasificación temporal.....	69
<b>Figura 36.</b> Correlación de índices espectrales en el humedal. ....	70
<b>Figura 37.</b> Clasificación no supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2017. ....	71
<b>Figura 38.</b> Clasificación no supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el año 2018 y primer trimestre del año 2019. ....	72
<b>Figura 39.</b> Clasificación supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2017. ....	75
<b>Figura 40.</b> Clasificación supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2018. ....	76
<b>Figura 41.</b> Temporalidad promedio de saturación en el humedal Pugllohuma. ...	77



## LISTA DE ACRÓNIMOS

**ACHSA:** Área de Conservación Hídrica Sostenible Artesana

**AI:** Inteligencia Artificial

**DEM:** Modelo de Elevación Digital

**DMQ:** Distrito Metropolitano de Quito

**EPMAPS:** Empresa Pública de Agua Potable y Saneamiento

**EPN:** Escuela Politécnica Nacional

**ESA:** European Space Agency

**FONAG:** Fondo para la Protección del Agua

**GEE:** Google Earth Engine

**L8:** Landsat-8

**ML:** Machine Learning

**PPPR:** Plains and Prairie Pothole Region

**PRCV:** Programa de la Recuperación de la Cobertura Vegetal

**RF:** Random Forest

**S1:** Sentinel-1

**S2:** Sentinel-2

**SAR:** Synthetic Aperture Radar

**UAVS:** Unmanned Aerial Vehicles

**UNESCO:** Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura

**USDA:** United States Department of Agriculture

**USFQ:** Universidad San Francisco de Quito

## RESUMEN

El estudio de áreas ambientalmente sensibles y sus servicios ecosistémicos se ha vuelto una prioridad alrededor del mundo, sobre todo en los objetivos de las instituciones públicas que administran recursos naturales. El humedal Pugllohuma fue seleccionado como el área de interés para este estudio porque se encuentra en el sistema La Mica Quito-Sur, que es uno de los cuatro sistemas de recolección de agua utilizados en la red de agua potable de Quito, y el estado conservación del humedal influye en el ciclo hidrológico del agua que llega a Quito. Dicho humedal se encuentra dentro del Área de Conservación Hídrica Sostenible Antisana en la microcuenca del río Jatunhuayco, al norte del sistema La Mica. El humedal y sus alrededores han sido comúnmente estudiados mediante sensores remotos ópticos. Sin embargo, el uso sensores ópticos para monitorear el humedal se ve limitado cuando la nubosidad del entorno es mayor al 60%. Por tal motivo, en los últimos 5 años se ha incrementado la búsqueda de técnicas que permiten un monitoreo permanente de esta área. En este sentido, el presente trabajo de investigación utilizó imágenes de radar para detectar cambios en el régimen hídrico del humedal Pugllohuma desde 2017 hasta 2019 y el proceso de clasificación de las imágenes de radar fue acelerado mediante el uso árboles de decisión para realizar clasificaciones supervisadas. De este modo, la construcción de modelos de clasificación supervisada señaló que los cambios espacio-temporales del humedal Pugllohuma se rigen primordialmente por el día del año, elevación del terreno, temperatura atmosférica, y precipitación. Además, los resultados de la clasificación supervisada indicaron que el nivel freático en el humedal tiene una distribución temporal de carácter estacional. Entonces resulta que el periodo de sequía en el suelo ocurre en los meses de enero, febrero y marzo, mientras los niveles freáticos altos fueron más frecuentes desde junio a septiembre y de noviembre a diciembre. De esta forma, el área de interés mostró sus cambios estacionales alrededor de la siguiente distribución de las clases de suelo que fueron consideradas en el presente trabajo: 170 ha de suelo seco, 17 ha de suelo húmedo, y 7 ha de suelo cerca de la saturación.

## ABSTRACT

The study of environmentally sensitive areas and their ecosystem services has become a priority worldwide, especially in public institutions' objectives that administer natural resources. The Pugllohuma wetland was chosen as the area of interest because it is in the Mica Quito-Sur system, which is one of the four water collection systems used in Quito's drinking water network, and the conservation status of the wetland influences the hydrological cycle of the water that reaches Quito. It is located within the Antisana Sustainable Water Conservation Area in the Jatunhuayco River's micro-basin, north of the La Mica system. The wetland and its surroundings had been commonly studied using optical remote sensor. However, the use of optical sensors is limited when cloud cover is greater than 60%. For this reason, in the last 5 years, there has been an increase in the search for techniques that allow permanent monitoring of this area. Therefore, the current research work used radar images to detect changes in the wetland's water regime from 2017 to 2019 and the radar image classification process was accelerated by means of decision trees to perform supervised classifications. Thereby, the building of supervised classification models evidenced that Pugllohuma wetland's space-time changes are governed by the day of the year, terrain elevation, atmospheric temperature, and precipitation. Also, the supervised classification results indicated that the wetland's water table had a temporal distribution of a seasonal nature. So, the soil drought season takes place in January, February, and March, whereas high water tables were more frequent from June to September, and from November to December. Because of that, the area of interest showed its seasonal changes around the following distribution of the soil classes which were considered in the present work: 170 ha of dry soil, 17 ha of moist soil, and 7 ha of soil near saturation.

## PRESENTACIÓN

De acuerdo con la Convención RAMSAR llevada a cabo por el Departamento de Caza y Pesca del Irán en 1971, el Comité Permanente de la Convención sobre los Humedales (2019), y United States Department of Agriculture (USDA) (2018), los humedales son diversos cuerpos de agua continentales temporales o estacionales poco profundos, y extensiones marinas de profundidad menor a 6 metros con suelos hídricos saturados fácilmente que promueven la vegetación hidrofítica. Dependiendo del tipo de humedal y sus características, estos proveen de servicios ecosistémicos de fácil percepción, como aportación de agua para consumo y riego, apoyo a la pesca continental, y respaldo de numerosas opciones de producción de energía (Finlayson, et al., 2018). Así mismo, al ser parte del ciclo hidrológico e interactuar con otros sistemas hídricos, estos pueden beneficiar a la sociedad al purificar el agua, almacenar contaminantes, y recargar reservas subterráneas. Otros autores, son más específicos al describir sus beneficios, pues aseguran que los humedales han desarrollado un papel vital para la evolución de las sociedades. Esto se basa en el hecho de que en ellos se encuentran los recursos vitales y ocurren procesos importantes para la supervivencia humana, desde la producción de alimento mediante la pesca, cultivos de arroz y frutos, hasta la producción de madera, fijación de carbono y otros (Lasso et al., 2014).

La pérdida y degradación de las características ecológicas de los humedales no solo está ligada a las demandas de la población, sino a las actividades implicadas en el desarrollo urbano. En Quito, el Fondo para la Protección del Agua (FONAG) junto con la Empresa Pública de Agua Potable y Saneamiento (EPMAPS) han identificado afectaciones antrópicas en los humedales altoandinos (FONAG, 2017). En este sentido, con el fin de cumplir sus objetivos institucionales de rehabilitación, cuidado y conservación de fuentes de agua, ambas instituciones han trabajado en el monitoreo, evaluación, y manejo del Área de Conservación Hídrica Sostenible Antisana (ACHSA) (EPMAPS y FONAG, 2018). El trabajo de preservar el ACHSA es parte del Programa de la Recuperación de la Cobertura Vegetal (PRCV), aplicado en áreas de conservación hídrica que han sido drenadas y sobrepastoreadas (FONAG, 2017). Así mismo, el presente trabajo de titulación apoya a

la EPMAPS y el FONAG desde el marco del proyecto PIJ-17-05 de la Escuela Politécnica Nacional que busca estudiar la dinámica de la vegetación y sus relaciones con el clima.

Dentro del área de interés se han realizado mapeos de composición florística de comunidades vegetales de cobertura vegetal natural y humedales, así como, niveles de intervención y tenencia de tierra (EPMAPS y FONAG, 2018). Durante el proceso de mapeo del humedal se han utilizado varias herramientas de teledetección ya que ha sido útil en la adquisición de información espacial y temporal de los humedales (Guo et al., 2017). En este sentido, durante el planteamiento del presente trabajo de titulación se ha escogido las virtudes de la tecnología radar para mapear el desarrollo espacio-temporal del humedal Pugllohuma en el ACHSA, y luego se analizaron las imágenes con un enfoque probabilístico a través de la aplicación de técnicas de aprendizaje supervisado con el algoritmo de random forest (RF). De esta manera, se visualiza y cuantifica la retrodispersión del humedal Pugllohuma para asociarla con valores de pendiente, elevación de terreno y la estacionalidad climática del área de estudio. El resultado de la clasificación muestra la variabilidad temporal que tiene la distribución de saturación en el humedal Pugllohuma (Mahdianpari et al., 2019; y Pekel et al., 2016).

# **CAPÍTULO 1. INTRODUCCIÓN**

## **1.1. ANTECEDENTES**

La población del Distrito Metropolitano de Quito (DMQ) ha logrado satisfacer sus necesidades vitales y productivas a través del aprovechamiento sostenible de fuentes hídricas en la cuenca alta del río Guayllabamba, principalmente por el trabajo del FONAG y EPMAPS (EPMAPS y FONAG, 2018). Dentro de la cuenca alta del río Guayllabamba se trabaja en cuatro sistemas de captación de agua: El Papallacta integrado, La Mica Quito Sur, y las dos conexiones Occidentales y Orientales (Sistema Integrado de Comunicación del Municipio, 2015). De este modo, para mantener el manejo adecuado de las microcuencas hidrográficas que abastecen al sistema de agua potable La Mica – Quito Sur, la EPMAPS adquirió el ACHSA en el 2011 y la coadministra con el FONAG (EPMAPS y FONAG, 2018).

En el ACHSA se empezó una serie de actividades en el año 2014 orientadas a la restauración del humedal Pugllohuma, terreno de 14.2 ha elegido por el alto número de drenajes y nivel de degradación de su cobertura vegetal (FONAG, 2016). La restauración comenzó por el monitoreo anual de una parcela dentro del humedal, con el fin de alejar la fauna y evaluar la presión que esta ejercía en el ecosistema (FONAG, 2016). Sin embargo, esta metodología pasiva fue reemplazada por una activa para acelerar los resultados (FONAG, 2019; e INABIO, 2020). La metodología activa consistió en la instalación de diques para evitar el excesivo drenaje y erosión del humedal, y el monitoreo de 16 pozos de nivel freático de agua por medio de una medición manual cada dos semanas aproximadamente y 2 pozos con medición automática cada 5 minutos (FONAG, 2019; e INABIO, 2020).

El FONAG y la EPMAPS han recibido apoyo desde la academia, principalmente de las siguientes instituciones: Escuela Politécnica Nacional (EPN), Universidad San Francisco de Quito (USFQ), y Universidad Central del Ecuador (UCE) (ECAP, 2018; Espinel, 2019; y Yugsi, 2018). Uno de los casos de apoyo desde la academia fue el desarrollo de una metodología para la evaluación de saturación del humedal, mediante el uso de Unmanned Aerial Vehicles (UAVS), limitados por las condiciones meteorológicas de vuelo, pero con una alta sensibilidad en la toma de

datos que son muy útiles para superficies pequeñas como estas (Espinel 2019; y Palma 2020). Por otro lado, como complemento al monitoreo del nivel freático, se han llevado a cabo estudios de vegetación de ribera y acuática del humedal; con la dirección de Esteban Suárez, Profesor, Director de la Maestría en Ecología (ECAP, 2018). También se ha caracterizado la hidrogeología del humedal para determinar la conductividad hidráulica mediante estudios litológicos, y las pruebas de doble anillo y del pozo invertido (Yugsi, 2018). Estos estudios indican que el drenaje mantiene una forma circular, y se evidencia una mayor retención desde el 2016.

## **1.2.OBJETIVOS**

### **1.2.1. OBJETIVO GENERAL**

Analizar la variabilidad espacio-temporal del humedal Pugllohuma mediante el uso de herramientas de teledetección.

### **1.2.2. OBJETIVOS ESPECÍFICOS**

- Identificar la relación entre los cambios espacio-temporales del humedal Pugllohuma, mediciones topográficas y climáticas.
- Clasificar las zonas de saturación con agua en el área de interés en las categorías permanente, estacional y eventual; mediante el uso de árboles de decisión.
- Validación de la clasificación y mapeo de los niveles de saturación con agua del suelo del humedal Pugllohuma.

## **1.3.ALCANCE**

La evaluación espacio-temporal en el nivel de saturación del humedal Pugllohuma obtiene sus resultados mediante la construcción de un modelo de clasificación supervisada en el que se ingresa una serie de imágenes de la misión Sentinel-1 (S1) con datos geoespaciales. Esto se realiza en la plataforma Google Earth Engine (GEE) y se apoya el proceso estadístico con el software R-Studio. Esta combinación de plataformas se debe a las limitaciones en el tiempo de procesamiento en el servidor de GEE y la cantidad de archivos descargables dentro de la cuenta de Google Drive de cada usuario (Navarro, 2017). De este modo, el

uso de R-Studio reduce la cantidad de trabajos a realizar en GEE para aprovechar el servidor en la aplicación de la clasificación supervisada a las imágenes radar.

La clasificación supervisada es una técnica que permite discretizar información de manera automática para reducir tiempos de operación. De este modo, la construcción de un modelo de clasificación supervisada requiere seleccionar información del campo de estudio de acuerdo al producto esperado. Por tal motivo, el presente trabajo limita el uso de variables meteorológicas a la discretización temporal de los días con alto y bajo nivel de saturación (Henderson y Lewis, 2008). Por otra parte, las imágenes SAR, valores de pendientes, y elevación de terreno se utilizan para evaluar el comportamiento espacial del humedal Pugllohuma (Gorelick, 2016).

En ese sentido, la clasificación supervisada del presente estudio es utilizada para definir los niveles bajos, medios y altos de saturación con agua en el suelo de acuerdo a la estacionalidad del humedal. La información de niveles de saturación se presenta en series de tiempo para monitorear el progreso que han tenido las técnicas de restauración en el humedal, ya que tanto la misión (S1) como el proyecto de restauración se han llevado a cabo durante un periodo similar (ESA y Fletcher, 2013; y FONAG, 2016). Por tal motivo, el estudio se evalúa dentro del periodo 2017 – 2019, cuando es más representativa la cantidad de imágenes SAR y registros del nivel freático en el humedal.

#### **1.4.JUSTIFICACIÓN**

La conservación y restauración de humedales, así como su uso sostenible, son esfuerzos que se realizan a nivel global por los numerosos beneficios que este ecosistema aporta a la humanidad. En Ecuador, el manejo del ACHSA comienza en el año 2011 con la EPMAPS como institución propietaria y el FONAG como institución coadministradora (EPMAPS y FONAG, 2018). La adquisición del ACHSA para su conservación se justifica por la pérdida ecosistémica durante el siglo XX, cuando el área fue erosionada con actividades de pastoreo intensivo y extensivo con alrededor de 22000 individuos, de los cuales el 77.3% fueron identificados como ovejas (EPMAPS y FONAG, 2018). El FONAG ha localizado humedales a lo



largo del ACHSA a través de visitas de campo, y en pocos se ha desarrollado técnicas de monitoreo por la falta de acceso a información. El humedal Pugllohuma es el humedal con mayor monitoreo en el ACHSA, contando con parcelas, pozos de control freático y mediciones físicas de calidad del agua.


En varios estudios se ha utilizado la tecnología radar para obtener delimitaciones de agua con una precisión mayor al 60% y resoluciones entre 10x10 metros y 30x30 metros (Chen et al., 2017; DeLancey et al., 2018; y Gabrielsen et al., 2016). Las diferentes ondas de los satélites de radar han permitido durante años establecer relaciones entre la vegetación y la respuesta al impulso, así como otras superficies (Mahdianpari et al., 2019; y Podest y McCartney, 2019). En este sentido, se han realizado esfuerzos por mapear, monitorear y administrar el aprovechamiento de humedales. Los radares son valiosos en la detección de humedales en áreas con elevado nivel de nubosidad por ser capaces de penetrar nubes e incluyendo el nivel de inundación (Podest y McCartney, 2019).

Así mismo, el uso de la clasificación supervisada facilita el manejo de extensas fuentes de información y la comprensión de la versatilidad de un ecosistema. En la mayoría de evaluaciones de los humedales se asocian los comportamientos a un solo parámetro discreto y no al conjunto de factores que componen un ecosistema (Gabrielsen et al., 2016). El uso de árboles de decisión permite tener un enfoque más completo de un ecosistema, al manejar simultáneamente diversas variables y extensas fuentes de información. Esta metodología permite utilizar información espacial y temporal de las variables recolectadas para comprender la versatilidad de los ecosistemas (Kennedy et al., 2018).

El aprovechamiento de nuevas fuentes de información y la agilización de su procesamiento ayuda a sustentar la administración de recursos en el DMQ. Es necesario asegurar el cuidado del agua desde su origen para reducir el riesgo de deterioro de calidad de agua. En este sentido, la conservación de los humedales dentro del área de interés, así como su monitoreo al ser un patrimonio nacional estratégico de uso público como se registra en la *Constitución del Ecuador* del 2008, deben ser supervisados permanentemente.

## CAPÍTULO 2. ESTADO DEL ARTE

En la actualidad se escoge el uso de imágenes satelitales ópticas para el monitoreo de ecosistemas. La limitación en el uso de imágenes satelitales ópticas es la presencia de nubes, así como, la ausencia de luminosidad sobre el área de interés para producir datos de calidad (Podest y McCartney, 2019). En respuesta, se ha optado por utilizar sensores radar de apertura sintética, por sus siglas en inglés SAR (Synthetic Aperture Radar), para superar obstáculos meteorológicos y horarios (Chen et al., 2017). Sin embargo, Baghdadi et al. (2001) junto con Mleczko y Mróz (2018) afirman que esta tecnología aún no ha sido desarrollada con especificidad para cada terreno en el que se quiera realizar una evaluación y por eso la eficiencia en la estimación de humedales solo se encuentra cercana al 60%. Hoy en día, el estudio de humedales con imágenes radar ha sido cubierto por diferentes campos científicos, especialmente en el estudio de las ciencias planetarias y terrestres como se muestra en la Figura 1.



**Figura 1.** Campos implicados en el mapeo de humedales con radar.

Fuente: Elsevier B.V. (2020)

Elaborado por: Paul David Carchipulla Morales

Además, la mayoría de los avances en el estudio de humedales de los últimos años convergen en el desarrollo de la inteligencia artificial, por sus siglas en inglés AI (Artificial Intelligence), para obtener resultados sobre el 90% de eficiencia (Guo et al., 2017). Un ejemplo de la aplicación de imágenes SAR y AI es el inventario de humedales canadienses identificados mediante clasificación supervisada en base a árboles de decisión. Sin embargo, los resultados del inventario de Canadá aún no son concluyentes por la falta de bases de cada tipo de humedal para retroalimentar el modelo (Amani et al., 2019). Mientras que en Estados Unidos, se monitoreó la región de baches de llanuras y praderas, por sus siglas en inglés PPPR (Plains and Prairie Pothole Region), de las Grandes Llanuras del Norte de los Estados Unidos mediante rasters acumulativos de probabilidad usando imágenes ópticas y radar (Gabrielsen et al., 2016). Las imágenes ópticas consiguieron mejores resultados que las imágenes de radar por la reducción de resolución en estas últimas al corregir el ruido que tienen las imágenes de radar. Los casos mencionados son solo algunas de las investigaciones realizadas con imágenes de radar para la teledetección de humedales.

## CAPÍTULO 3. MARCO TEÓRICO

### 3.1.HUMEDALES

El manual de la convención Ramsar (2006) dispone que los humedales continentales son suelos saturados con agua a un nivel freático cerca de la superficie y los cuales se pueden clasificar en temporales, permanentes o estacionales. En el caso de extensiones marinas, los humedales se distinguen de otros ecosistemas por la profundidad menor a 6 metros con suelos hídricos saturados fácilmente que promueven la vegetación hidrofítica (Rojas, 2018; UNESCO, 1971; y USDA, 2018). En ambos casos se destaca la homogeneidad en el terreno, así como la estrecha dependencia del medio y la vida al agua; entendiéndose de esta forma que los humedales son delimitados por su condición hídrica (Secretaría de la Convención Ramsar, 2006). La caracterización de un humedal requiere de datos de hidrología, geomorfología, edafología, geoquímica, biología y ecología (Lasso et al., 2014). Al reconocer varios componentes de un humedal se puede reconocer la diversidad de humedales intrínsecos de cada región, y estación del año. Algunos ejemplos se encuentran en la Tabla 1, manteniéndose su nombre en inglés por la ausencia de traducciones exactas en la mayoría de términos.

**Tabla 1.**  
*Ejemplos de humedales en el mundo.*

Billabong	Es una referencia australiana que describe a la lagunas y piscinas remanentes en canales de corrientes.
Bog	Se destaca la acumulación de turba, la ausencia de entradas y salidas significativas y armoniza con los musgos acidófilos.
Bottomland	Tierras bajas, generalmente con inundaciones aluviales constantes en superficies boscosas a lo largo de arroyos y ríos.
Carr	La vegetación es predominantemente leñosa.
Delta	Ubicados generalmente en desembocaduras. Los sedimentos aluviales se asientan en forma de abanico.
Estuary	Los estuarios, por su nombre en español, presentan dilución de aguas continentales con las marítimas.
Fen	Además de la acumulación de turba, es posible el drenaje del suelo mineral circundante.

Flark	Una depresión temporal o permanente que alberga vegetación por la inundación presente junto con la acción de turba.
Intertidal flat	Son estuarios sin cubierta vegetal y una superficie plana o poco inclinada, a veces expuestos a inundaciones por mareas.
Lagg	Corriente que bordea un pantano
Lake	Cuerpo de agua lótico rodeado por tierra
Lagoon	Cuerpo de agua lótico profundo, generalmente ubicado en deltas.
Loch	Término irlandés y escocés para una entrada de lago o mar.
Mangrove	Los manglares, por su nombre en español, son ambientes intermareales con poca energía, cuya vegetación es representada por arbustos y árboles.
Marsh	Las inundaciones son frecuentes o permanentes, promoviendo que la vegetación herbácea emerja en un sustrato mineral.
Mire	Referencia a las turberas, con cualquier concentración de turba.
Moor	Referencia a las turberas. Un "highmoor" equivale a un bog elevado, mientras que un "lowmoor" es una turbera en una cuenca que no está elevada por encima de su perímetro
Muskeg	Término norteamericano para largas áreas de turberas y bogs.
Peatland	Es un ecosistema con una capa natural mayor a 30 cm de turba acompañada de una saturación permanente con agua.
Playa	Depresión en regiones áridas a semiáridas, donde se presentan estaciones secas y húmedas.
Polje	Depresiones con drenajes kársticos. Estas depresiones pueden ocurrir en época seca o húmeda.
Pond	Estancamiento de agua.
Pothole	Estanques no profundos, singulares de Estados Unidos y Canadá.
Reed swamp	Definición europea para los humedales dominados por la caña.
Rhyne	Un término inglés para los drenajes que transforman humedales en suelos húmedos.
Riparian system	Sistemas cercanos a corrientes o ríos, elevando su nivel freático.
Sabkha	Costas salinas evaporativas con incrustaciones salinas definidas.
Salt marsh	Desde la región media a alta intertidal se presentan especies vegetativas tolerantes a la sal.
Slough	Pantanos y lagos poco profundos del oeste de Estados Unidos.
Swale	Depresión alargada entre dunas y crestas costeras.
Swamp	Humedales dominados por arbustos. En Europa son dominados por especies leñosas o juncos.
Tarn	Lago pequeño entre montañas sin tributarios significativos.

Tidal freshwater marsh	Se encuentran cerca de ríos y estuarios, lo suficiente como para ser afectados por las mareas sin concentraciones salinas.
Turlough	Depresiones poco profundas en suelos kársticos carboníferos inundado principalmente por aguas subterráneas.
Vernal pool	Estancamientos temporales por estaciones húmedas.
Vlei	Humedales estacionales o lagos intermitentes en Sudáfrica.
Wet meadow	Pastizales anegados sin estancamientos en la mayor parte del año.
Wet prairie	El nivel freático es intermedio entre pantanos y prados húmedos.

Fuente Finlayson, et al., 2018

Cada tipo de humedal tendrá efluentes y afluentes específicos dados por la atmósfera, estratos terrestres superficiales o subsuperficiales, sistemas marinos, entre otros. Cuando la atmósfera influye predominantemente en el nivel del agua del humedal, los afluentes principales pueden ser lluvia, nieve, granizo, aguanieve, neblina, y rocío; mientras que el efluente será la evapotranspiración (North y Kim, 2017). En cambio, al tener mayor influencia por intercambios superficiales, el humedal tendrá épocas con flujo base, y otras con flujo tormenta causados por flujos laminares, intercambios directos con cuerpos de agua lóticos a través del humedal, inundaciones en época húmeda por sobrepasar la capacidad de reservas colindantes, y bordes de lagos, estuarios, mares (Finlayson, et al., 2018). Por otra parte, los intercambios subsuperficiales son más difíciles de identificar ya que tienden a ser más complejos por el flujo horizontal y vertical, donde se pueden observar intercambios por drenaje poco profundo, inducción topográfica de tierras altas, o descargas de acuíferos.

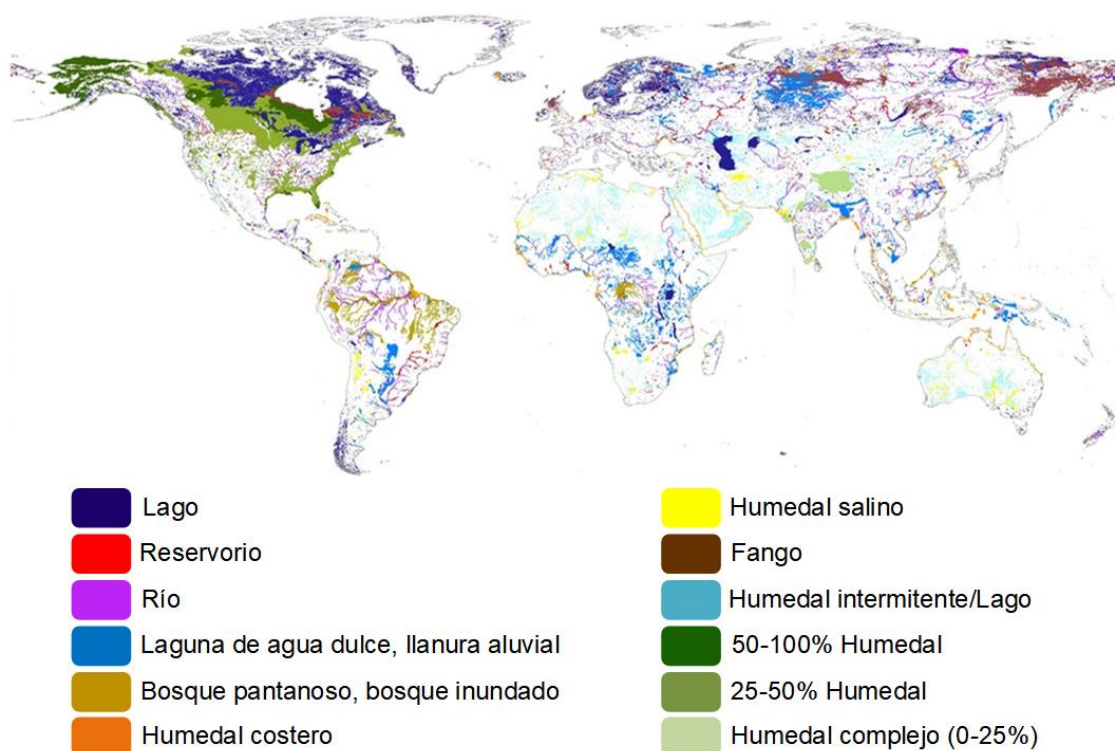
### 3.1.1. DESTRUCCIÓN DE LOS HUMEDALES

En la actualidad se ha impulsado significativamente la conservación de humedales, al concientizar su alta productividad a pesar de solo cubrir el 6% de la superficie terrestre (Álvarez, 2019). Aun así, los actuales esfuerzos tienen que lidiar con años de agricultura e industrialización que acabaron con la mitad de humedales en el mundo durante el siglo XX (Maltby, 2009). Esto quiere decir que otro 6% de la superficie terrestre también correspondía a extensiones de humedales a comienzos del siglo XX y fueron reemplazadas para el desarrollo de actividades antrópicas (Maltby, 2009).

### 3.1.2. PROTECCIÓN DE LOS HUMEDALES

Los humedales proveen innumerables servicios ecosistémicos directos a la humanidad y otros indirectos como el soporte de ecosistemas a su alrededor. Entre sus virtudes destacan la aportación de agua para consumo y riego, apoyo a la pesca continental, respaldo de numerosas opciones de producción de energía, y participación en diferentes ciclos como el del carbono (Vepraskas y Craft, 2016). Un ejemplo de la inmensa importancia de los humedales son las plantaciones de arroz, principal alimento para la mitad de la población en el planeta (Álvarez, 2019).

Por su importancia alrededor del mundo se han realizado esfuerzos por ubicar y proteger los humedales del planeta, y crear ecosistemas artificiales similares a los humedales (Figura 2). Se conocen algunos casos exitosos de protección, por ejemplo, se logró que en Canadá y U.S.A. protegieran permanentemente a más de 110000 km<sup>2</sup> y de forma provisional a más de 60000 km<sup>2</sup> de humedales (Amani et al., 2019). Estos casos mejoraron las prácticas legislativas en Canadá y U.S.A., promoviendo acciones restaurativas y creando nuevas políticas territoriales. En Europa, tras el compromiso de 19 países se llegó a proteger ecosistemas envueltos dentro de la cuenca del río Danube (Finlayson, et al., 2018). El Camargue, delta del río Rhône en el Mediterráneo, ha llegado a ser alterado con flujos artificiales para mantener sus servicios ecosistémicos (Finlayson, et al., 2018). Lastimosamente, en Sudamérica no se han presentado los mismos esfuerzos que en el resto del mundo, reflejándose en la escasa literatura que estudia a los humedales. En esta región, los humedales cubren el 30% de la superficie; significando un gran aporte al agua, fertilidad del suelo e hidrología de la Amazonía (Lasso et al., 2014). En Ecuador existen 18 sitios RAMSAR, de los cuales 10 se encuentran en la costa, 1 en la región insular, 4 en la sierra, 1 en el oriente, y 2 entre la sierra y oriente (MAAE, 2019).



**Figura 2.** Distribución global de lagos, reservorios y humedales.

Fuente: Finlayson, et al., 2018

### 3.2.HUMEDALES ALTOANDINOS

La región andina se encuentra en Latinoamérica, y como se mencionó anteriormente existe escasa bibliografía que haga referencia a los humedales como parte de esta región. En la bibliografía actual de humedales se estudia los humedales altoandinos como cuerpos de agua lénticos. Además, dentro de dicho estudio destacan tres categorías de humedales altoandinos: lagunas altoandinas profundas, lagunas altoandinas someras, y turberas altoandinas (Lasso et al., 2014).

Las lagunas altoandinas profundas son sistemas lacustres permanentes de aguas transparentes, cuyo origen puede ser glaciario, volcánico o tectónico; identificándose alrededor suelos orgánicos de orden histosol (Lasso et al., 2014). Estas características asocian a las lagunas altoandinas profundas con cuerpos de agua lóticos, donde lagunas con formas cóncavas son producto del movimiento rotacional de glaciares, y aquellas con geoformas son producto de grandes masas

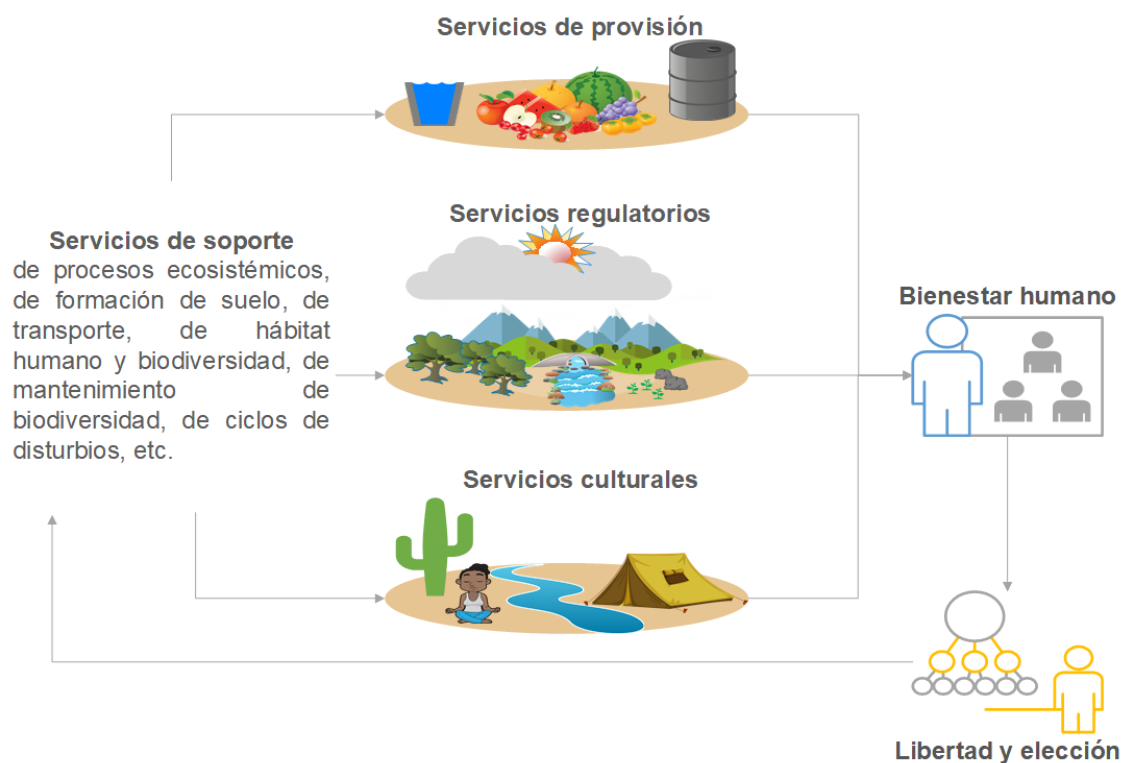


de hielo glaciario (Schulz y Lobosco, 2011; y Steinberg, 2012). También puede darse el caso de que las lagunas altoandinas se formen por dolinas y cavernas (Schulz y Lobosco, 2011; y Steinberg, 2012). A diferencia de las lagunas altoandinas profundas, aquellas que son someras pueden ser temporales y no tienen origen volcánico, sino morrénico (Lasso et al., 2014). Lo que significa una mayor superficie por el bajo nivel del agua delimitada por morrenas, donde el intercambio de flujos podría llegar a secar el cuerpo de agua en periodos cortos de tiempo.

En cambio, las turberas altoandinas son sistemas palustres permanentes de aguas claras ubicados en depresiones de terreno o sitios con deficiencia de drenaje (Hribljan et al., 2017; y Lasso et al., 2014). Este ecosistema se caracteriza por bajas temperaturas y geomorfología que limita la descomposición de materia orgánica, formando turbas (Hribljan et al., 2017). Esto quiere decir que el nivel de agua es somero y el suelo es de orden histosol (INABIO, 2020). Se estima que las turberas altoandinas se extienden a lo largo de la cordillera oriental colombiana hasta el macizo del Táchira en la frontera con Venezuela, y que en Ecuador representan menos del 1% de la superficie total del país (Hribljan et al., 2017; INABIO, 2020; y Lasso et al., 2014). A pesar de su pequeña extensión en Ecuador, las turberas altoandinas podrían contener aproximadamente el 23% del carbono fijado superficial y subsuperficialmente en los bosques ecuatorianos (Hribljan et al., 2017).

### **3.3.SERVICIOS ECOSISTÉMICOS DE LOS HUMEDALES ALTOANDINOS**

Los servicios ambientales o ecosistémicos son procesos naturales de los ecosistemas, y que benefician a la humanidad directa o indirectamente (MEA, 2005; y Vepraskas y Craft, 2016; Figura 2). Los servicios ecosistémicos no se limitan a afectar a humanidad, sino que también tienen funciones ecológicas que conservan y regulan la vida (*Código Orgánico Del Ambiente*, 2017). Aun así, el aprovechamiento de los servicios de los humedales no es administrado adecuadamente por la falta de entendimiento del funcionamiento de su entorno (de Groot et al., 2010).



**Figura 3.** Servicios ecosistémicos y bienestar humano.

Fuente: *Código Orgánico Del Ambiente*, 2017; Vepraskas y Craft, 2016

Elaborado por: Paul David Carchipulla Morales

La mayor parte de los servicios brindados por los humedales altoandinos tienen un valor indirecto, o es más bien un beneficio para futuras generaciones (Tabla 2). Entre algunos ejemplos de los servicios no evidentes a simple vista están: recarga de acuíferos, purificación de agua, valor cultural (Finlayson, et al., 2018). Aun así, en función de la clase de humedal y características específicas de su suelo tendrá una mayor o menor generación de un servicio. En el caso de las tres clases de humedales altoandinos revisados anteriormente se muestra la siguiente tabla, identificando sus servicios ecosistémicos más representativos.


**Tabla 2.***Servicios ecosistémicos de humedales altoandinos.*

Servicio	Lagunas altoandinas profundas	Lagunas altoandinas someras	Turberas altoandinas
Aprovisionamiento	Agua potable Agua de riego Hidroeléctricas Pesca	Agua para especies silvestres Aporte en sistemas hídricos	Agua para ganado. Recurso genético.
Regulación	Caudales y acuíferos Clima local o regional Fijación CO2 Erosión Purificar atmósfera Riesgos naturales	Clima local Flujo de agua local y regional Erosión Polinización Riesgos naturales	Flujo de agua local. Calidad del aire. Clima. Erosión. Polinización.
Cultural y amenidad	Ecoturismo, y pesca deportiva Valores espirituales, paisajísticos, y recreativos	Ecoturismo. Valores espirituales, paisajísticos, y recreativos.	Valores estéticos y ecoturismo.
Soporte y Hábitat	Hábitat permanente o temporal de aves y anfibios.	Hábitat permanente o temporal de aves y anfibios.	Alimento para fauna silvestre.

Fuente: Lasso et al., 2014

### 3.4. TELEDETECCIÓN DE HUMEDALES

Existen muchas técnicas para monitorear humedales entre las cuales se encuentran las técnicas manuales y automáticas, así como detecciones próximas y remotas. No obstante, para el estudio espacio-temporal de los humedales se prefiere la aplicación de sensores remotos (Navarro, 2017). La información recolectada puede ser una medida de la respuesta de un objetivo al impulso emitido por un sensor armado en un satélite, recolectando de este modo propiedades y características de dicho objeto (Miraglia et al., 2010). El modo de operación de los sensores remotos puede entenderse comúnmente con la Figura 4, donde se observa la fuente de energía (sol), interactuar con el objetivo (superficie terrestre), mientras el sensor mide la energía o impulso y la interpreta para retransmitirla como información a los usuarios.



**Figura 4.** Modo operacional de sensores remotos.

FUENTE: Miraglia et al., 2010

Elaborado por: Paul David Carchipulla Morales

Los satélites artificiales tienen una serie de características que limitan su aplicación ya que estos son diseñados para un propósito en específico (Liebig, 2005; y Miraglia et al., 2010). En este sentido, cada misión satelital tiene una trayectoria orbital y resolución que se ajustan a sus objetivos. Para explicar mejor estas características, se presenta la Tabla 3.

**Tabla 3.**

*Características de los sensores remotos.*

Característica	Descripción
Parámetros orbitales	Órbita geoestacionaria: giran con el globo terráqueo y se sitúan en el Ecuador. Órbita polar: pasan las proximidades de los polos N-S, resultando en una división de la órbita, donde no se recolecta información (pasiva) y donde sí obtienen información (activa).
Resolución de los sensores	Resolución espacial: es el área que cubre el sensor para discriminar objetivos. Resolución de impulso: medida de sensibilidad para diferenciar las respuestas en la interacción impulso-objetivo.

	<p>Resolución radiométrica: número de niveles digitales que se utilizan para presentar la información tomada por el sensor.</p> <p>Resolución temporal: tiempo que toma al satélite volver a la misma superficie.</p>
--	---

Fuente: Miraglia et al. (2010)

De acuerdo con Guo et al. (2017), desde 1964 hasta 2013 se presenta un crecimiento exponencial en los estudios de humedales mediante el uso de sensores remotos. En el sentido de mostrar la cantidad de investigaciones realizadas entre 1964 y 2013, la Tabla 4 presenta un resumen de los sensores y enfoques de las investigaciones de humedales con sensores remotos durante dicho periodo. También es pertinente mencionar que este periodo de tiempo es cuando se realizaron más investigaciones de humedales con sensores remotos, ya que hasta el 2013 se registraron aproximadamente 550 investigaciones anuales y en 2015 el número descendió a 500.

**Tabla 4.**

*Número de publicaciones utilizando sensores remotos en investigaciones de humedales de 1964 a 2013.*

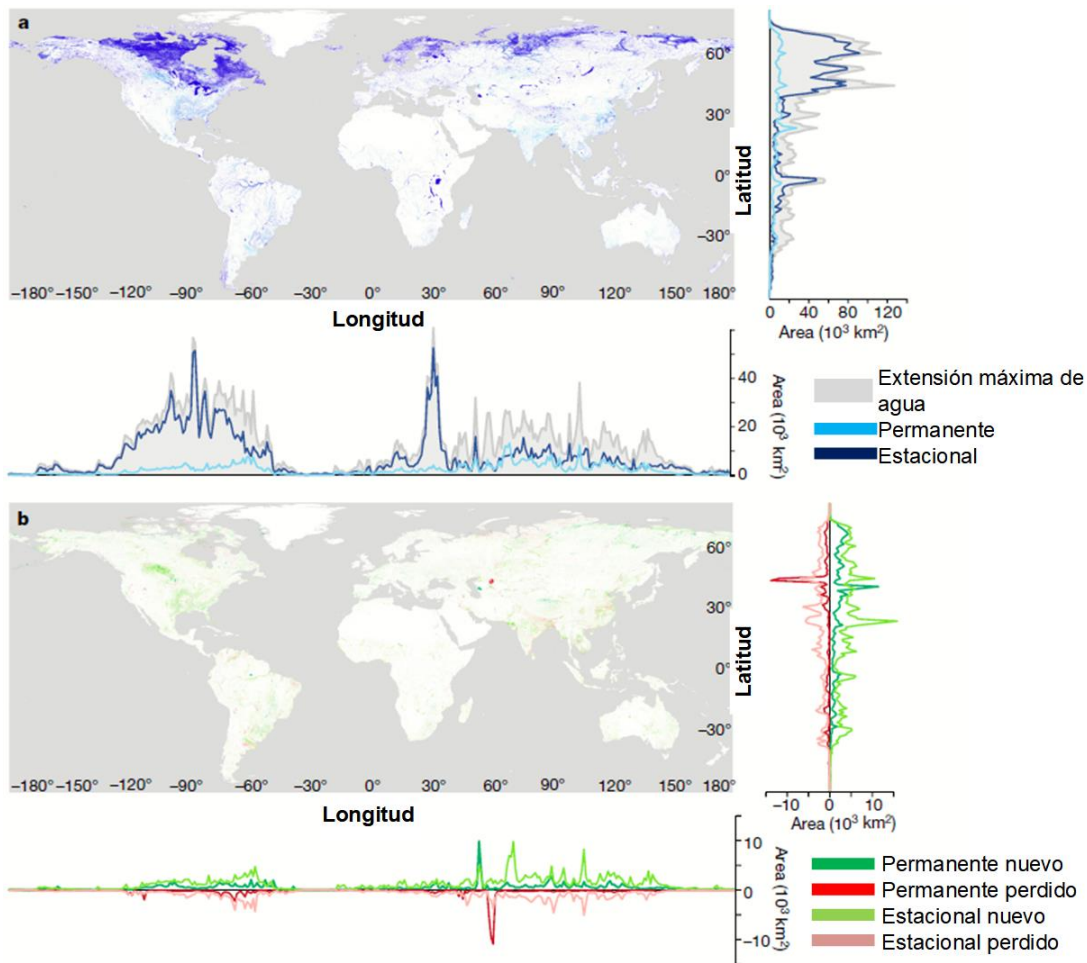
Tema	Aéreo	Baja Resolución	Media Resolución	Alta Resolución	Hiper-espectral	Radar	Lidar
Vegetación	456	332	710	166	209	387	156
Uso/cambios en suelos	184	189	594	118	59	197	75
Clasificación	200	117	664	170	147	291	89
Hábitats	221	34	199	46	38	62	59
Conservación	141	37	218	44	22	63	36
Cambio Climático	85	73	126	16	9	70	39
Biomasa	59	56	141	37	51	121	58
Restauración	120	27	100	17	6	37	33
Hidrología	74	26	96	9	11	98	37
Biodiversidad	54	29	115	15	10	37	32
Modelado	40	42	72	17	10	57	44
Inundaciones	57	47	117	11	5	126	21
Disturbios	70	21	65	8	11	22	12

Detección de cambios	29	25	149	27	8	43	8
Nivel marino	77	14	49	9	15	28	57
Calidad del agua	30	12	55	11	8	26	12
Humedad del suelo	7	29	40	11	9	83	7
Servicios ecosistémicos	20	12	64	9	8	15	21
Sedimentación	48	4	30	4	1	24	14
Evapotrans.	6	45	29	2	2	10	6
$\Sigma$	1978	1171	3633	747	649	1797	811

Fuente: Guo et al. (2017)

Se puede destacar que el sensor más utilizado es el de resolución media, el cual incluye a sensores ópticos como Landsat TM/Enhanced Thematic Mapper Plus (ETM+), Advanced Spaceborn Thermal Emission and Reflection Radiometer (ASTER), China y Brazil Earth Resource Satellite (CBERS), Système Probatoire D'Observation de la Terre (SPOT 1-4), y Advanced Land Observing Satellite (ALOS) Advanced visible near infrared radiometer type 2 (AVNIR-2) (Guo et al., 2017). Por lo que no es de asombro que se llegara a desarrollar mapas de alta resolución de cambios temporales en el agua superficial en el planeta (Pekel et al., 2016). La Figura 5 es el resultado de una de las investigaciones más ambiciosas en los últimos años, exhibiendo en el literal a) Extensión máxima del agua, ocurrencia permanente y estacional de agua superficial de octubre de 2014 a octubre de 2015. Mientras que en el literal b) se muestran Ganancias y pérdidas en el área de aguas superficiales permanentes y estacionales entre 1984 y 2015.

Sin embargo, este tipo de tecnologías son limitadas por la cantidad de luz presente. Es necesario que existan condiciones meteorológicas que no impidan la incidencia de radiación para que el sensor pueda obtener mediciones de los objetivos, lo que significa que tampoco sería posible trabajar en un horario nocturno (Pascual, 2018). Aun así, siguen siendo preferidas por la información de alta calidad que se puede obtener, como los índices espectrales que han presentado mayor eficiencia en delimitación y caracterización de ecosistemas (Guo et al., 2017; y Pascual, 2018).



**Figura 5.** Distribución y cambios en el agua superficial global.


Fuente: Pekel et al. (2016)

### 3.5. RADARES DE APERTURA SINTÉTICA EN MAPEO DE HUMEDALES

Los SAR tienen la ventaja de poder trabajar en condiciones climáticas que inhiben la captura de información satelital; por ejemplo, el porcentaje de nubosidad o eventos de precipitación. Esta ventaja se debe a que los SAR no requieren de una fuente externa para iluminar el objetivo como en el caso de los sensores ópticos espectrales (Pascual, 2018). Los SAR tienen su propia fuente de energía para identificar objetivos mediante la recepción y transmisión de radiación electromagnética polarizada (Moreira, 2013). Esto significa que el sensor podrá trabajar tanto en el día como en la noche (White et al., 2015). Además, lleva su nombre por el movimiento de la antena en la plataforma del satélite, simulando una

mayor elongación para mejor resolución con una antena pequeña (Podest, 2018a). Las imágenes obtenidas usualmente se observan en una escala de grises para representar el cálculo del tiempo entre el pulso que es emitido por el radar y el que regresa al sensor (Pascual, 2018). En estas imágenes destaca la capacidad de siempre obtenerse una imagen de alta resolución espacial por penetración del impulso a través de nubes, y dependiendo de la resolución del impulso se puede penetrar el dosel del ecosistema estudiado (White et al., 2015).

A pesar de esto, ciertas distorsiones todavía son manifestadas al crear una imagen de radar (Figura 6). En la siguiente figura se muestra una imagen de radar de la misión RADARSAT-1 del área del Lago Nahuel Huapí, ascendente y con mirada a la derecha. La Figura 6 es un ejemplo de una imagen radar afectada por las distorsiones de shadowing, foreshortening y layover; proporcionada por Toth y Lenzano (2014).



**Figura 6.** Distorsiones en una imagen radar.

Fuente: Toth y Lenzano (2014)

El desplazamiento del relieve (foreshortening) es una simulación de compresión en laderas o pendientes inclinadas hacia la trayectoria radar (Toth y Lenzano, 2014; y White et al., 2015). De este modo se reflejan casi al instante las respuestas, acortando la pendiente y obteniéndose tonos más claros en la imagen. La inversión



por relieve (layover) es dado en desplazamientos extremos del relieve, llegando primero la energía de la cima que la de la base (Toth y Lenzano, 2014; y White et al., 2015). De este modo, la cima aparece como volcada hacia el sensor. Las sombras (shadowing) son frecuentes en imágenes de radar, ubicándose detrás de objetos elevados o de laderas muy pronunciadas (Toth y Lenzano, 2014; y White et al., 2015). Esto se asocia usualmente con zonas de la superficie del terreno que no fueron iluminadas por el radar. Existe otra distorsión en las imágenes, el cual es un efecto visual de sal y pimienta llamado moteado o en inglés speckle. El speckle consiste en la interferencia de las ondas reflejadas difusamente por otros objetos en el área de interés (Moreira, 2013).

En el Parque Nacional Tanjung Putig, trópico de Indonesia, ya se han dado inicio al estudio de turbas en bosques de manglares y la evaluación de las variables del SAR que dominan en la clasificación de terreno. En este estudio se probó la importancia de la dirección de recolección de datos (anisotropía) y ruido de la imagen (entropía) ante cualquier otra variable (Wohlfart et al., 2018). Examinando estas características de los radares satelitales junto con la constante dieléctrica alta y reflectancia especular del agua, es altamente recomendado utilizar la tecnología SAR para la teledetección de agua, humedad de suelo y retención de agua en plantas (Henderson y Lewis, 2008; y White et al., 2015). Las imágenes muestran un color negro intenso para representar al agua como se ve en la Figura 6.


Las técnicas de teledetección de humedales usando SAR tienen una eficiencia entre 60% y 90% en la identificación de humedales (Guo et al., 2017; y Shuman y Ambrose, 2003). En los estudios de humedales que utilizan tecnología SAR destaca que el éxito se atribuye a especificaciones del sensor, objetivos del estudio, y características del entorno (Henderson y Lewis, 2008). No obstante, se ha notado un aumento de preferencia por las técnicas que usan umbrales en las respuestas del objetivo y probabilidades de incidencia (Henderson y Lewis, 2008; Podest, 2018a; y White et al., 2015). En ecosistemas altoandinos como el páramo, donde están presentes especies florísticas de altura baja como los musgos, ciperáceas y gramíneas, es recomendado utilizar una resolución de impulso amplia para

asegurar la penetración del impulso en el suelo (Mleczko y Mróz, 2018; y Wohlfart et al., 2018)

### **3.6.SENTINEL-1**

La misión S1 es una iniciativa por parte de la Global Monitoring for Environment and Security (GMES) y la European Space Agency (ESA) para proveer de manera gratuita información para monitorear ecosistemas y aplicaciones de seguridad (ESA y Fletcher, 2012). Esta misión se incluye en un programa de lanzamientos de una serie de satélites a lo largo de 20 años, cada uno con una vida útil de 7.5 años (ESA y Fletcher, 2012; y Podest y McCartney, 2019). La misión S1 trabaja con dos satélites gemelos que orbitan polarmente la tierra y se separan por fases de 180°, disponiendo de una frecuencia de vuelo sobre el ecuador cada 6 días (ESA y Fletcher, 2012).

Los satélites capturan la información en 4 modos de adquisición, que se pueden visualizar en la Figura 7. El más destacado es el modo de franja ancha interferométrica por cubrir satisfactoriamente superficies de interés, evita problemas y mantiene la incidencia de vuelo en puntos estratégicos, y simplifica las planificaciones de vuelo (ESA y Fletcher, 2012). El modo de franja ancha interferométrica reduce costos de vuelo y otorga información robusta de calidad. Aun así, se utilizan otros modos de captura por los intereses entre los involucrados en el desarrollo del proyecto (ESA y Fletcher, 2012). Características de los modos de captura con las siglas de sus nombres en inglés se presentan a continuación en la Tabla 5.



**Figura 7.** Modos de captura de imágenes radar S1.

Fuente: ESA y Fletcher (2012)

**Tabla 5.**

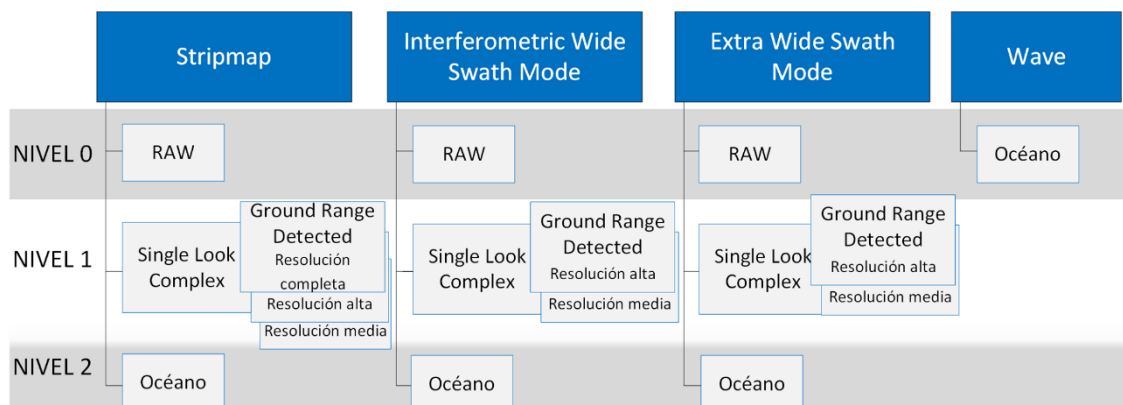
*Características de los modos de captura S1.*

Parámetro	Interferometría de franja ancha (IW)	Onda (WV)	Mapa de Franjas (SM)	Franja extra ancha (EW)
Polarización	Dual (HH+HV, VV+VH)	Singular (HH, VV)	Dual (HH+HV, VV+VH)	Dual (HH+HV, VV+VH)
Incidencia	31° - 46°	23° + 37° (ángulo de incidencia media)	20° - 47°	20° - 47°
Resolución azimut	20 m	5 m	5 m	40 m
Resolución del rango de suelo	5 m	5 m	5 m	20 m

Azimut y rango de vista	Singular	Singular	Singular	Singular
Ancho	250 km	Viñeta 20 km x 20 km	80 km	410 km
Ruido máximo equivalente a sigma cero (NESZ)	-22 dB	-22 dB	-22 dB	-22 dB
Estabilidad radiométrica	0.5 dB ( $3\sigma$ )	0.5 dB ( $3\sigma$ )	0.5 dB ( $3\sigma$ )	0.5 dB ( $3\sigma$ )
Precisión radiométrica	1 dB ( $3\sigma$ )	1 dB ( $3\sigma$ )	1 dB ( $3\sigma$ )	1 dB ( $3\sigma$ )
Error de fase	5°	5°	5°	5°

Fuente: ESA y Fletcher (2012)

Así mismo, cada tipo de captura tiene un nivel de imagen de acuerdo al procesamiento de la información recolectada. Un diagrama de cómo se distribuyen se muestra en la Figura 8. El nivel 0 es específico de los datos recolectados y almacenados que pasan al nivel 1 al ser corregidos por errores de los equipos utilizados (Podest, 2018a). Este nivel es el que se distribuye por plataformas, pues los niveles siguientes se refieren a la aplicación en un campo (nivel 2) y la validación de resultados tras su uso (nivel 3) (ESA y Fletcher, 2012). Por lo que para seleccionar la mejor alternativa de tecnología SAR se debe considerar que la respuesta al impulso electromagnético o retrodispersión se debe a la estructura de los objetos en la superficie y las propiedades bioeléctricas de la superficie (Podest, 2018b). Estas repuestas electromagnéticas se miden y controlan por medio de la longitud de onda, polarización y ángulo de incidencia en los equipos utilizados.



**Figura 8.** Niveles de procesamiento de imágenes S1.

Fuente: (ESA y Fletcher, 2012)

### 3.6.1. LONGITUD DE ONDA

La longitud de onda es la distancia entre las crestas de dos ondas y define la interacción de la señal con el medio (Podest y McCartney, 2019). Cada longitud de onda tiene rangos de estudio que permiten atravesar doseles e incluso superficies de suelo seco y nivel hasta 1 m de profundidad, estos rangos se los conoce como bandas (El Hajj et al., 2019; Guo et al., 2017; y Podest y McCartney, 2019). Esta clasificación de bandas se presenta a continuación en la Tabla 6, agregando entre paréntesis las longitudes de onda más utilizadas en ciertas bandas.

**Tabla 6.**

*Longitudes de onda de radares satelitales.*


Designación de banda	Longitud de onda ( $\lambda$ ), cm	Frecuencia ( $\nu$ ), GHz ( $10^9$ ciclos * $\text{seg}^{-1}$ )
Ka (0.86 cm)	0.8 – 1.1	40.0 – 26.5
K	1.1 – 1.7	26.5 – 18.0
Ku	1.7 – 2.4	18.0 – 12.5
X (3.0 cm, 3.2 cm)	2.4 – 3.8	12.5 – 8.0
C (6.0)	3.8 – 7.5	8.0 – 4.0
S	7.5 -15.0	4.0 – 2.0
L (23.5 cm, 25 cm)	15.0 – 30.0	2.0 – 1.0
P (68 cm)	30.0 – 100.0	1.0 – 0.3

Fuente: ESA y Fletcher, (2012)

La misión S1 trabaja con la banda C, beneficiando a la evaluación de humedales, ya que es preferible usar resoluciones de impulso altas cuando la vegetación tiene un dosel bajo (Mahdianpari et al., 2019). La intención es buscar que la longitud de onda tenga un tamaño similar al objeto estudiado porque de otro modo la interacción es nula o mínima (Amani et al., 2019). Por otro lado, Mleczek y Mróz (2018) aseguran que al comparar la banda C con la banda X en terrenos con más de 4 clases es mejor utilizar la banda X. Además, El Hajj et al. (2019) agregan a la afirmación previa que cuando se estudia plantaciones agrícolas es necesario considerar los periodos de cultivo, debido a los cambios bruscos de geometría en el terreno en periodos cortos.

### 3.6.2. POLARIZACIÓN

La polarización se refiere al plano en el que se propagan las señales desde el radar, siendo transmitidos y recibidos horizontal (H) y verticalmente (V) (Schwert et al., 2018). Estas señales siempre existirán en un impulso de radar, pero solo se leen las de interés para el que fue diseñado el sensor. La Tabla 5 muestra algunas clases de polarizaciones, donde se aprecia que estas se definen por 2 letras. La primera letra se refiere al plano de lectura de salida y la segunda es el plano de retorno. Por este motivo, los radares trabajan con lecturas: horizontales-horizontales (HH), verticales-verticales (VV), horizontales-verticales (HV), y verticales-horizontales (VH) (Catry et al., 2018). Para entender mejor la idea de polarización se pone a disposición la siguiente figura.



**Figura 9.** Efecto de la polarización en objetos.


Fuente: Fernandez et al. (2015)

Elaborado por: Paul David Carchipulla Morales

En la Figura 9 se puede apreciar que cada polarimetría tiene un área de efecto diferente en un mismo objeto. Incluso es común que la retrodispersión medida en cada polarización tenga valores diferentes (Baghdadi et al., 2001). Así mismo, ciertas polarizaciones tienen una elevada capacidad de diferenciar entre agua superficial y vegetación inundada. En este contexto, las polarizaciones HH y VV son utilizadas para teledetección de agua, mientras que HV y VH se prefieren en la identificación de vegetación (Schwert et al., 2018). Sin embargo, es común preferir la polarización HH porque es menos propensa a confundir áreas inundadas con áreas de abundante vegetación (Fernandez et al., 2015).

### **3.6.3. ÁNGULO DE INCIDENCIA**

El ángulo de incidencia es aquel que se forma a partir del impulso emitido con respecto a la perpendicular del objeto, mostrado gráficamente en la Figura 10 (Makynen y Karvonen, 2017). Existe discrepancias entre si el ángulo de incidencia afecta o no en la retrodispersión. A pesar de esto, las investigaciones conducen a creer que entre mayor sea la fluctuación del ángulo de incidencia temporalmente, mayor va a ser la entropía en los datos (Marechal et al., 2012). Se ha registrado que las variaciones hasta aproximadamente  $2^{\circ}$  en el ángulo de incidencia no tienen repercusiones en la información (Marechal et al., 2012). Los ángulos de magnitud mayor serán aquellos que se encuentren más cerca del sensor, en tanto que los de menor magnitud estarán más alejados del sensor y tendrán mayor penetración en el suelo, así como un color más brillante en la imagen (Mahdianpari et al., 2019). Por este motivo es importante tener inicialmente un análisis de la variabilidad del ángulo de incidencia, teniendo en cuenta también que no siempre habrá una variabilidad significativa.



**Figura 10.** Efecto del ángulo de polarización en objetos.

Fuente: Makynen y Karvonen (2017)

Elaborado por: Paul David Carchipulla Morales

#### 3.6.4. TEMPORALIDAD

Esta característica del sensor no afecta en su funcionamiento, pero sí lo hace en el análisis de datos. La cuantificación de las variaciones en las dinámicas de los humedales es esencial tanto espacial como temporalmente, durante este proceso se ha evidenciado que el lapso de tiempo entre 2 imágenes a comparar afecta en las clasificaciones de humedales (Catry et al., 2018). Es por eso que este se debe mantener menor a 6 meses (Catry et al., 2018). En el caso de los SAR, ese no es un problema porque las imágenes son recuperadas con más frecuencia al tener una propia fuente de energía y no estar afectados por las condiciones meteorológicas. De este modo, la recuperación de información aumenta su frecuencia y facilita el estudio de ecosistemas en un solo año o estación (Bourgeau-Chavez et al., 2015). En el caso de S1, las imágenes se recuperan cada 12 días



por parte de dos satélites artificiales gemelos con trayectoria orbital que tiene como punto de encuentro la línea equinoccial (Corbane et al., 2019).

Por el contrario, los trabajos de clasificación de ecosistemas que trabajan con PALSAR tienen lapsos de 24 días entre captura de información. Estos trabajos han requerido 15 imágenes para cubrir con éxito la variabilidad estacional y 117 imágenes para cubrir la variabilidad anual en costas norteamericanas, respectivamente (Bourgeau-Chavez et al., 2015). Además, al trabajar con estudios temporales es importante reconocer que el muestreo de detección de agua para modelados supervisados puede tener umbrales diferentes a lo largo de un año (Behnamian et al., 2017). Esto suele suceder por el cambio que sufre el terreno en periodos secos y húmedos, o por actividades humanas, desarrollo de biomasa, entre otras variaciones en el área de interés. En esos casos, es importante generar muestras para cada periodo e identificarlo dentro de la muestra.

### **3.7.MACHINE LEARNING**

La inteligencia artificial, por sus siglas en inglés AI (Artificial Intelligence), es una rama de la informática que se ocupa de construir softwares capaces de responder a tareas autónomamente como lo haría un cerebro humano (Ramasubramanian y Singh, 2019; Rebala et al., 2019). Una de las metodologías con más éxito en desarrollar algo aproximado a la AI es el Machine Learning (ML) (Rebala et al., 2019). Este campo de las ciencias computacionales estudia algoritmos y técnicas de aprendizaje de datos existentes para reconocer nuevas bases de datos (Ramasubramanian y Singh, 2019; Rebala et al., 2019). Al reemplazar las técnicas convencionales se evita el problema de iteración de un proceso que se vuelve impráctico.

A su vez, el ML tiene subcategorías o acercamientos desde diferentes metodologías. Entre ellas se destacan el aprendizaje: supervisado, no supervisado, semi-supervisado, y de refuerzo (Ramasubramanian y Singh, 2019; Rebala et al., 2019). El aprendizaje supervisado trabaja con datos ya clasificados para estructurar un modelo que clasifique nuevas bases de datos (Rebala et al., 2019). Al contrario, las otras subcategorías de ML trabajan sin esa base de datos inicial, trabajan

parcialmente con ella, o la variabilidad espacio-temporal produce múltiples resultados (Ramasubramanian y Singh, 2019). Aun así, al hablar de ML se tiene un flujo de proceso ideal que consiste en: planear, explorar, construir y evaluar (Gorelick, 2016).

Es posible trabajar con diferentes algoritmos para obtener un modelo de ML, por lo cual se recomienda trabajar con ciertas consideraciones antes de elegir el método. Algunas de ellas son: costo, tipo de variable, inestabilidad de datos, disponibilidad de datos, tiempo de procesamiento, nivel de procesamiento de datos, entre otros (Ramasubramanian y Singh, 2019). Es por ello que, al hablar de inestabilidad climática como variable, acceso a un servidor, y bases de datos ya clasificados se suele recomendar trabajar con algoritmos de árboles de decisión (Gabrielsen et al., 2016; y Ramasubramanian y Singh, 2019).

### **3.7.1. RANDOM FOREST (RF)**

Random Forest (RF) es un conjunto de algoritmos a base de árboles de decisión que fueron diseñados para modelaciones de clasificación y regresión, donde se trabaja con  $B$  submuestras de una base de datos  $D$  para crear un modelo de ML (Breiman, 2001; Sullivan, 2017). En cada submuestra se coloca aproximadamente 62.38% de los datos de  $D$ , seleccionados al azar, para luego realizar iteraciones que permitan obtener la clasificación más frecuente y acertada (Rebala et al., 2019; y Zednik, 2019). Para esto, se distinguen los nodos hoja y los nodos de decisión dentro del árbol (Rebala et al., 2019). El nodo hoja es el resultado de la clasificación, mientras que el de decisión es el umbral que separa las clases (Ramasubramanian y Singh, 2019).

Es evidente que los árboles de decisión tendrán muestras similares o pueden tener el mismo dato repetido dentro de sí mismo, por la selección al azar. Lo que podría resultar en cierto grado de incertidumbre. A pesar de esto, tras valoraciones de la cantidad de datos en una variable y el error en clasificación se puede distinguir entre usar o no esta metodología a un problema en cuestión (Breiman, 2001; y Zednik, 2019). Esto se hace mediante la medición de la Entropía de los datos o el Índice de Gini (Breiman, 2001; Rebala et al., 2019; y Sullivan, 2017; Tabla 7). Las

ecuaciones presentadas en la siguiente tabla permiten medir la dispersión de resultados, cuando  $p_i$  es la frecuencia relativa de observaciones y  $C$  es el número de clases (Sullivan, 2017).

**Tabla 7.**

*Ecuaciones de clasificación en Random Forest.*

Medidas de dispersión	Ecuación
Gini	$G = 1 - \sum_{i=1}^C (p_i)^2$
Entropía	$E = \sum_{i=1}^C -p_i * \log_2(p_i)$

Fuente: Breiman, 2001; Sullivan, 2017

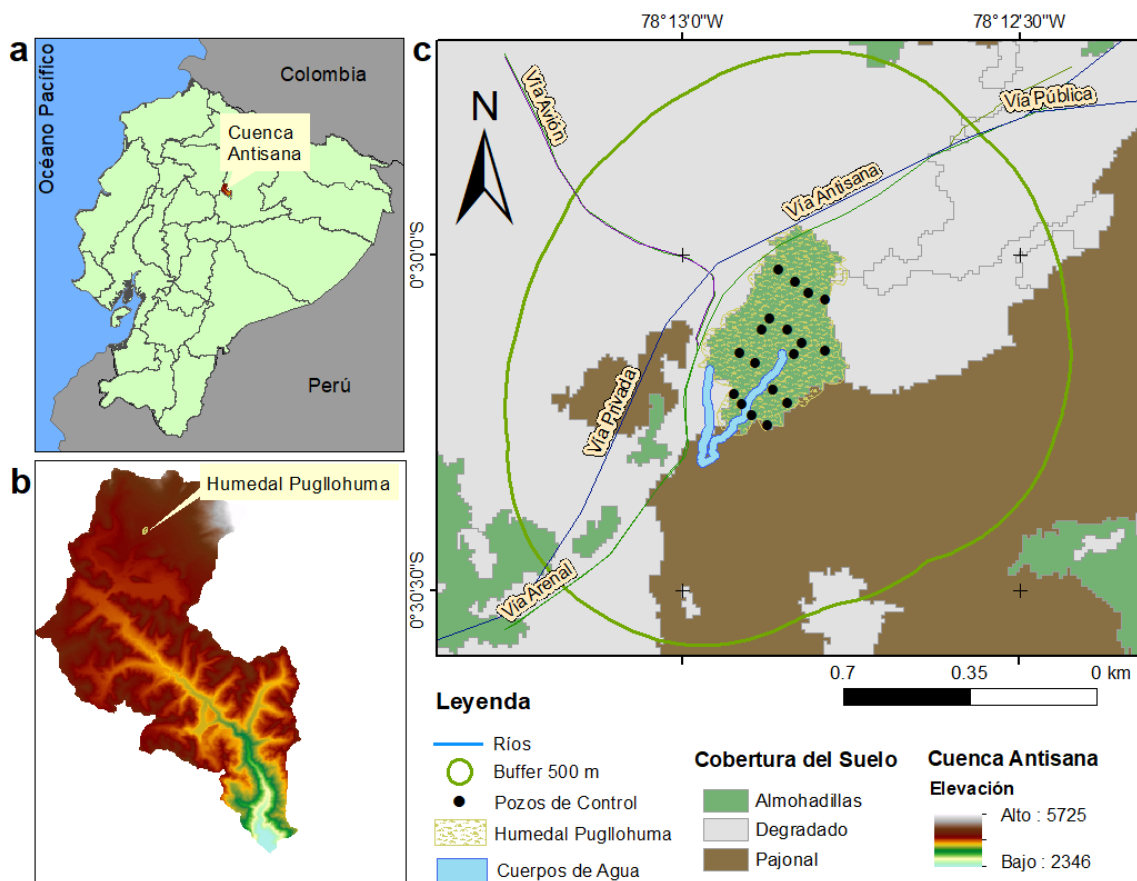
### 3.7.2. K-MEANS

K-means es un método de agrupamiento de datos por sus características, al calcular usualmente distancias cuadráticas (Wu, 2012). Esta es una técnica de clasificación altamente utilizada para clasificaciones espaciales (Ahmed y Akter, 2017; y Phiri y Morgenroth, 2017). Durante la clasificación resalta el término centroide para hacer referencia al punto de referencia de cada clase para medir la dispersión de los datos a clasificar (Wu, 2012). Primero, se definen el número de clases a utilizar. Segundo, el algoritmo de clasificación toma una muestra para medir distancias entre la información y agrupar en función del número de clases solicitado. Finalmente, el promedio de distancias en la muestra se utiliza para clasificar el resto de la información y si se requiere se define un nuevo centro clasifique la mayor parte de la información. La posición del centro de los datos se calcula repetidamente hasta que no sea necesario cambiarlo para clasificar la información ingresada.

## **CAPÍTULO 4. ÁREA DE ESTUDIO**

El área de interés es el humedal Pugllohuma, por ser uno de los primeros en presentar su propio plan de restauración dentro del Área de Conservación Hídrica Sostenible Antisana. Dicho humedal se encuentra en la microcuenca del río Jatunhuayco, al norte del sistema La Mica, a una altura que oscila los 4136 m.s.n.m., bordeado al oeste por 4 vías de acceso, y albergando una gran cantidad de almohadillas; como se encuentra registrado en la Figura 11b y la Figura 11c. El humedal posee una superficie de aproximadamente 14.2 ha y 40 drenajes artificiales, de acuerdo a los estudios previos del FONAG (EPMAPS y FONAG, 2018). Alrededor de este humedal se ha delimitado un radio de 500 metros para definir el área de estudio (llamado buffer en la Figura 11c) para evaluar la variación espacial de la saturación del suelo.

Se debe mencionar que el área de interés ha permanecido constante en las imágenes recolectadas entre 2017 y 2019. En ciertos estudios, el cambio acelerado de cobertura o uso de suelo ha provocado que durante el desarrollo de un trabajo se modifique el área o región de interés por el aumento o disminución de clases (Hribljan et al., 2017). En respuesta a estos cambios, suele optarse por definir un nuevo polígono en función de las clases o utilizando el criterio de expertos, aunque esta segunda alternativa no es óptima para todos los casos. De acuerdo a la información del FONAG y EPMAPS, el periodo de estudio utilizado no tiene cambios en la cobertura de suelo ni en su uso, debido a que el predio se encuentra dentro de una zona de conservación hídrica (EPMAPS y FONAG, 2018; y FONAG, 2016; Figura 11c). Esto permite utilizar el polígono que contiene al humedal delimitado por estudios anteriores en todas las fechas para las que se realizará la clasificación supervisada (Ghosh et al., 2014).



**Figura 11.** Información cartográfica del humedal Pugllohumas. Figura a) Ubicación de la cuenca Antisana a nivel de país. Figura b) Modelo digital de terreno de la cuenca Antisana. Figura c) Ubicación e información del humedal Pugllohumas.

Fuente: EPMAPS y FONAG, 2018


Elaborado por: Paul David Carchipulla Morales

#### 4.1. USO DE SUELO

La hacienda Contadero tuvo un uso intensivo en actividades agropecuarias por varios años, hasta que fue adquirido por la EPMAPS en el 2011 (FONAG, 2018; y Yugsi, 2018). Desde el 2011, las actividades llevadas a cabo en el actual ACHSA tienen como meta principal la gestión y conservación del mismo (Espinel 2019; FONAG 2017; y Palma 2020). En el humedal Pugllohumas se llevaron a cabo actividades de restauración pasivas y activas desde el 2014 (INABIO, 2020). Las actividades de restauración consistieron en la limitación del acceso al humedal desde el 2014 hasta el 2016, y la posterior instalación de vertederos que prolonguen la retención de humedad en el suelo (FONAG, 2016; y INABIO, 2020).

## 4.2. SUELO

Estudios locales del humedal y alrededores han concluido que el origen del suelo es volcánico, volviéndose arenosos a mayor profundidad (FONAG, 2016; y Yugsi, 2018). Esta relación entre la profundidad y la incidencia de suelo se muestra en la Figura 12. La siguiente figura muestra un perfil de suelo en el humedal Puglllohuma con los siguientes cortes: (A) 0-50 cm; (B) 0.5-1 m; (C) 1-1.5 m; (D) 1.5-2 m; (E) 2-2.5 m; (F) 2.5-3 m; (G) 3-3.5 m. Los estudios en el suelo del área de interés muestran que la superficie del área de estudio tiene una alta carga de materia orgánica. A su vez, las erupciones del volcán Antisana han cubierto de suelo negro el área de interés formando capas delgadas de ceniza y escoria en varios horizontes (Yugsi, 2018). También se puede identificar capas de ceniza y lapilli de escoria negra y fragmentos de roca intercalados con depósitos de sedimentos glaciario-fluviales y fluviales (Yugsi, 2018).

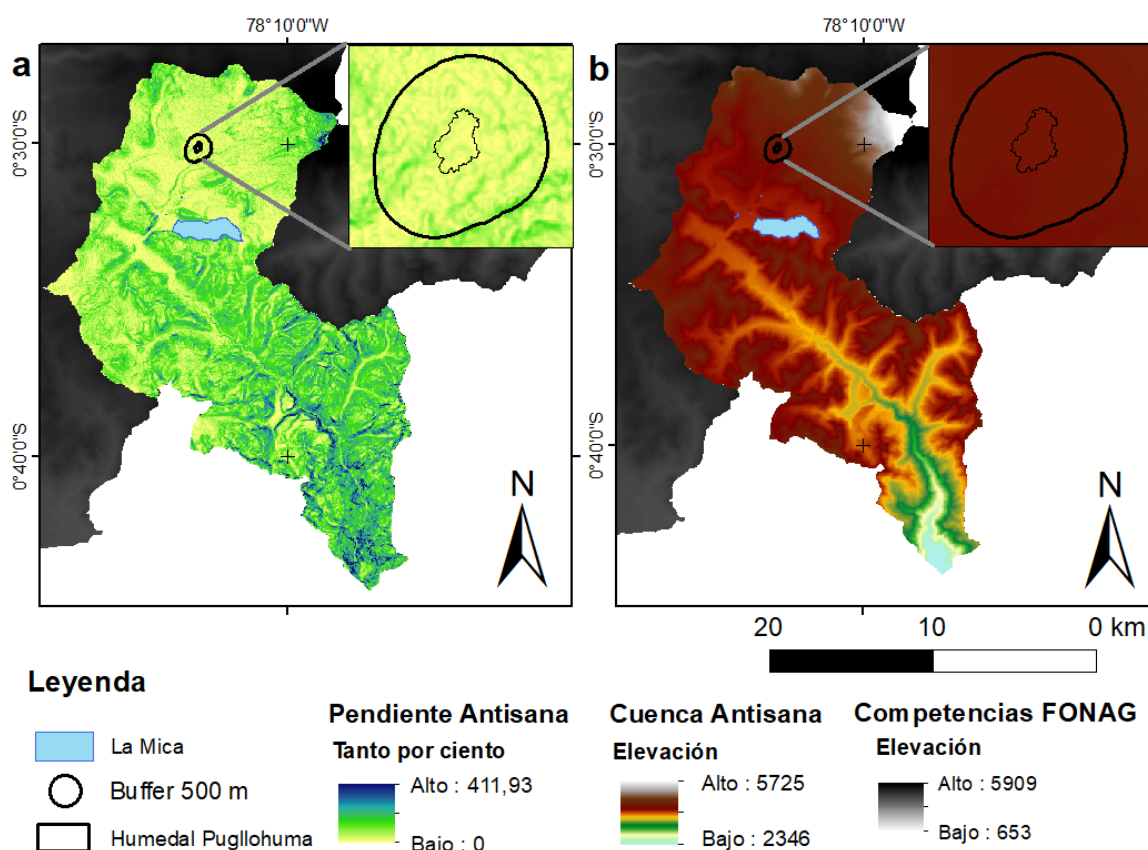


**Figura 12.** Perfil de suelo en el humedal Puglllohuma: (a) 0-50 cm; (b) 0.5-1 m; (c) 1-1.5; (d) 1.5-2 m; (e) 2-2.5 m; (f) 2.5-3 m; (g) 3-3.5m.

Fuente: FONAG, 2016

### 4.3. CUENCA HIDROGRÁFICA

El humedal Pugllohuma se encuentra dentro de la cuenca hidrográfica del río Antisana, la cual fue delimitada en 2017 por su aporte al sistema La Mica - Quito sur (EPMAPS y FONAG, 2018). En dicha cuenca se registra un rango de altura entre los 2300 y los 5700 m.s.n.m., y una media de 4000 m.s.n.m. (Figura 13a.). En el caso de la pendiente dentro de la cuenca, la Figura 13b muestra un rango entre 0 y 411.93%, y una media de 33%. En contraste, el área de estudio se encuentra entre los 4084 y 4145 m.s.n.m., con una media de 4136.35 m.s.n.m., y sus pendientes oscilan entre 0 y 48.7%., con una media de 10%. Por último, el humedal influye en la cuenca por encontrarse en la zona de recarga hídrica, aunque la pendiente del terreno no favorezca el flujo hacia el drenaje principal de la cuenca.



**Figura 13.** Información cartográfica de la cuenca Antisana. Figura a) Modelo digital de pendientes de la cuenca Antisana y el humedal Pugllohuma. Figura b) Modelo digital de terreno de la cuenca Antisana y el humedal Pugllohuma.

Fuente: EPMAPS y FONAG, 2018

Elaborado por: Paul David Carchipulla Morales

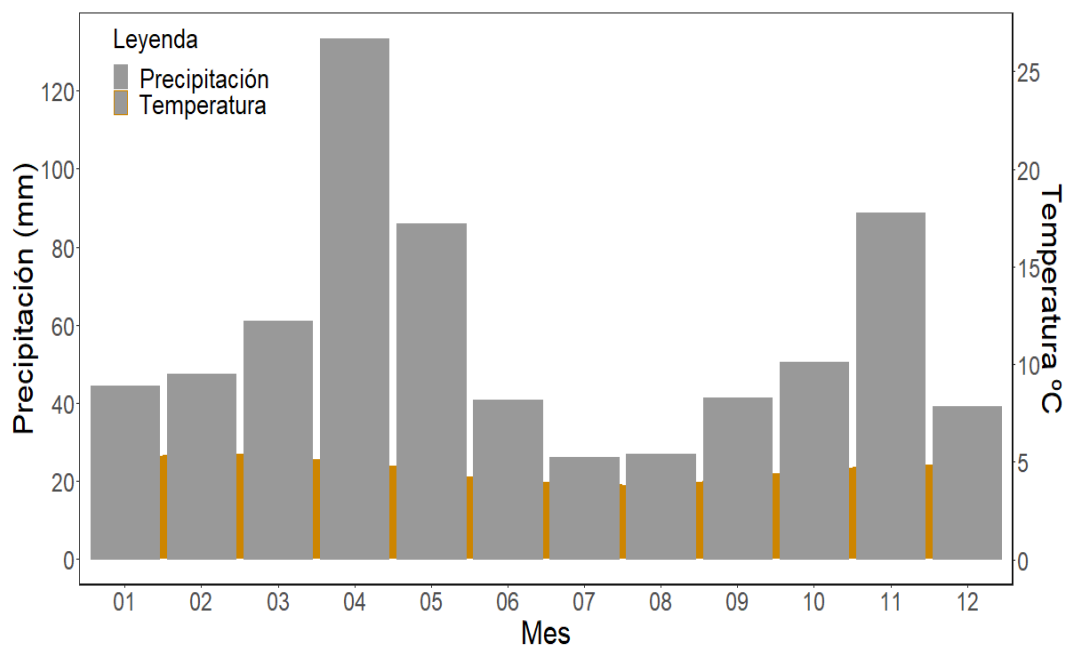
#### **4.4. VARIABLES CLIMÁTICAS EN EL HUMEDAL PUGLLOHUMA**

En esta sección se utilizan los datos de las estaciones M5125, y M5126 para describir mensualmente la variabilidad del clima del humedal Pugllohuma entre octubre de 2015 y enero de 2020. De este modo, la visualización de datos de precipitación, temperatura, dirección y velocidad del viento muestran una distribución bimodal en el humedal (Figura 14 y Figura 16). En este sentido, el periodo seco se comprende entre los meses de enero, febrero, julio, agosto y septiembre, mientras los periodos húmedos ocurren de abril a junio y de octubre a diciembre.

Durante los meses secos, la precipitación tiene un valor bajo los 40 mm/día, la temperatura promedio es de 4 °C al inicio del año y 3 °C en el tercer trimestre del año, mientras la velocidad del viento es de aproximadamente 7 m/s con un origen del sur (Figura 14). Por otro lado, en los meses húmedos, la precipitación supera los 60 mm/día, la temperatura se mantiene cercana a los 5 °C, y la velocidad del viento es de aproximadamente 5 m/s con un origen en el sureste (Figura 15). En cambio, la presión atmosférica se mantiene alrededor de los 600 mbar durante todo el año, así como la humedad relativa con un valor de 90% (Figura 16).

Cabe destacar que al revisar los registros climáticos diarios del humedal se puede encontrar eventos de precipitación de hasta 21.77 mm/día, humedad relativa del 100 % y velocidad del viento sobre los 15 m/s. Por el contrario, la temperatura puede llegar a disminuir hasta los 2 °C. Esta diferencia entre los datos diarios y los promedios mensuales muestra la versatilidad del tiempo en el humedal. También es notorio que las variables climáticas en el humedal tienen diferentes comportamientos en el segundo y cuarto trimestres del año. En el caso de la precipitación y temperatura, las dos variables se correlacionan negativamente en el segundo trimestre, mientras que en el cuarto trimestre se correlacionan positivamente. Algo similar ocurre con la dirección y velocidad del viento, ya que se correlacionan inversamente en el segundo trimestre, pero no muestran correlación alguna en el cuarto trimestre. Estas correlaciones se estudiaron a más profundidad en el capítulo 6.2 Gráficas de representatividad de variables temporales.

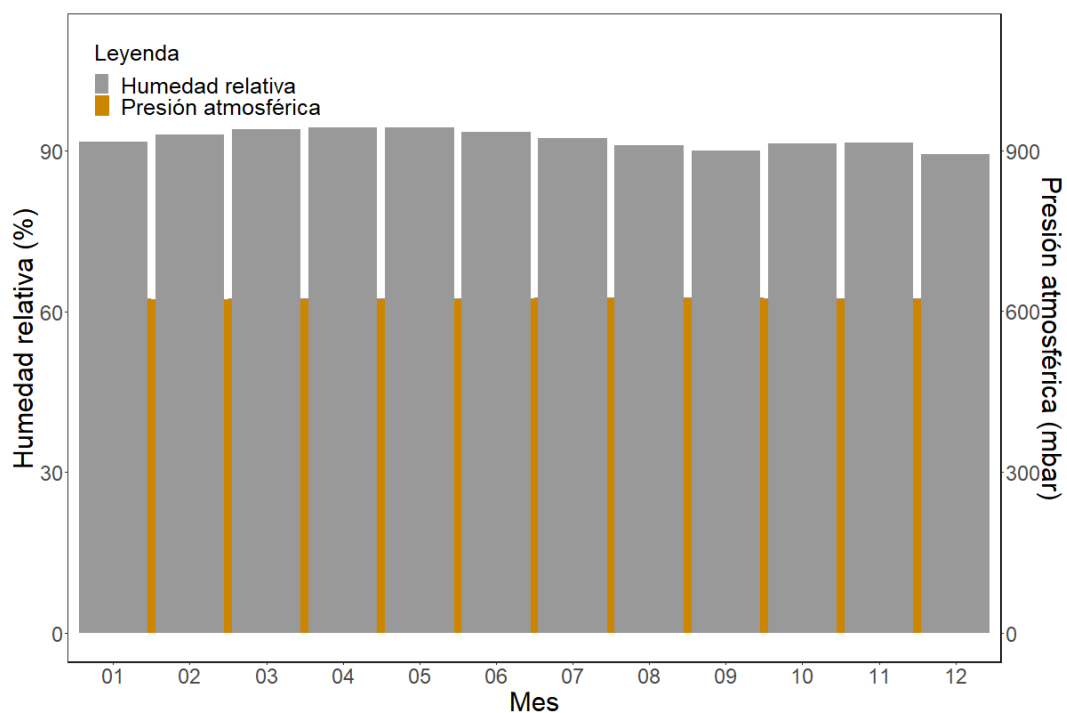




**Figura 14.** Promedio mensual de precipitación y temperatura en el humedal.

Fuente: Páez-Bimos, 2018; FONAG, 2019; INAMHI, 2020


Elaborado por: Paul David Carchipulla Morales



**Figura 15.** Promedio mensual de presión y humedad relativa en el humedal.

Fuente: Páez-Bimos, 2018; FONAG, 2019; INAMHI, 2020

Elaborado por: Paul David Carchipulla Morales



**Figura 16.** Promedio mensual de dirección y velocidad del viento en el humedal.

Fuente: Páez-Bimos, 2018; FONAG, 2019; INAMHI, 2020

Elaborado por: Paul David Carchipulla Morales

#### 4.5. CONDUCTIVIDAD HIDRÁULICA

La capacidad de recarga potencial anual en el humedal se estima alrededor de los 183 mm (Yugsi, 2018). Además, este almacenamiento hidráulico se conduce a una velocidad de 0.14 m/día hasta las salidas del humedal (Yugsi, 2018). Estos valores son variables por los regímenes de inundación que han sido modificados por los drenajes artificiales (FONAG, 2017). Se espera que las actividades de restauración implementadas puedan mejorar la capacidad de recarga en un futuro cercano, junto con una prolongación del tiempo de retención hidráulica.

## CAPÍTULO 5. METODOLOGÍA

### 5.1.RECOPIACIÓN DE INFORMACIÓN

Berry et al. (2019) plantean que la recolección preliminar de información es crítica para reconocer las variables que rigen los resultados de la clasificación supervisada. En este estudio se necesitaron variables que definan cambios temporales y otros que lo hagan en cambios espaciales. Un ejemplo de interpretación de cambios temporales son las medidas de nivel freático que definen temporadas de mayor o menor saturación (Schumacher y Klesschulte, 2010). Entre tanto, los cambios espaciales son medidos por la polarización de la retrodispersión, porque son sensibles a la presencia del agua (Podest, 2018b). A continuación, se describe la información que fue utilizada para el monitoreo del humedal y una descripción de donde se extrajo la misma.

#### 5.1.1. INFORMACIÓN DE MONITOREO DEL HUMEDAL PUGLLOHUMA


Entre los productos de monitoreo del ACHSA se encuentran modelos de elevación digital del terreno con resolución de 12m x 12m, una delimitación espacial del humedal Pugllohuma y vías de acceso. Esta geodata mencionada es el resultado de estudios cartográficos y sobrevuelos de drones (FONAG, 2016). Capturas como la mostrada en la Figura 17, permitieron incluso identificar el área de drenaje dentro del humedal.



**Figura 17.** Captura aérea del humedal Pugllohuma.

Fuente: FONAG, 2016

Además, dentro del área del humedal Pugllahoma se ubican 18 pozos de control de nivel freático a 1 metro bajo la superficie; utilizando tubería perforada PVC de 3" cubierta de tela tipo visillo para filtrar el agua que ingresa (FONAG, 2016). La Figura 18 muestra la forma en que los pozos permiten medir el agua albergada en el suelo. Estos pozos se colocaron con el fin de monitorear la dinámica hídrica del humedal desde el noviembre de 2016 hasta la actualidad a través de mediciones manuales en 16 pozos, aproximadamente cada 15 días, y mediciones automáticas cada 5 minutos en 2 pozos. Esta información del monitoreo del humedal fue solicitada al FONAG para utilizarla en los modelos de clasificación.



**Figura 18.** Pozo de control freático.

Fuente: FONAG, 2016

### 5.1.2. IMÁGENES SATELITALES

S1 es una misión satelital con la virtud de identificar fácilmente cuerpos de agua a pesar de limitaciones meteorológicas; permitiendo estudios temporales sobre áreas de interés (Podest, 2018a). Por otro lado, la misión Sentinel-2 (S2) permite realizar estudios espaciales más amplios y en cierto nivel estudios temporales dependiendo de la disponibilidad de imágenes (Mehta y Flores, 2018; y Podest, 2018a). En primera instancia, las imágenes S1 y S2 son accesibles a través de páginas oficiales de la ESA como el foro COPERNICUS (Corbane et al., 2019). Aun así, diferentes plataformas han adquirido las imágenes y las proveen con las primeras correcciones necesarias. Entre estas plataformas se encuentra a: CREODIAS,

ONDA, Mundi, Sobloo, y GEE (Corbane et al., 2019; y Navarro, 2017). Para este estudio, tanto las imágenes radar como las ópticas fueron adquiridas desde la plataforma GEE para utilizarse en la clasificación espacial y su validación. Dicha plataforma emite al público imágenes S1 de procesamiento nivel 1 e imágenes S2 de procesamiento nivel 1 y nivel 2. Estas imágenes se filtran de acuerdo a sus especificaciones presentadas en la Tabla 8 y Tabla 9.

**Tabla 8.**  
*Imágenes S1 en Google Earth Engine.*

Descripción	Esta colección incluye las escenas S1 Ground Range Detected (GRD), procesadas usando el software Sentinel-1 toolbox para generar un producto calibrado y ortocorregido.
Actualización	La base de datos se actualiza a diario, agregando imágenes dos días después de que el foro oficial las libere al público.
Propiedades	Resolución: 10, 25 y 40 metros Bandas: VV, VH, VV+VH, HH+HV, y ángulo de captura Modo de captura: SM, IW y EW
Correcciones	Remoción de ruido térmico Calibración radiométrica Corrección de terreno usando SRTM 30 o ASTER DEM para áreas mayores de 60 grados de latitud, donde SRTM no está disponible. Los valores finales corregidos por el terreno se convierten a decibelios a través de la escala del registro ( $10 * \log_{10}(x)$ ).

Fuente: ESA y Fletcher, 2012

Elaborado por: Paul David Carchipulla Morales

**Tabla 9.**  
*Imágenes S2 en Google Earth Engine.*

Descripción	S2 es una misión de imágenes multiespectrales de alta resolución y amplia franja usada en estudios de Monitoreo de la Tierra de COPERNICUS. Incluye el monitoreo de vegetación, suelo, cubierta de agua, vías navegables, y áreas costeras.
Actualización	La base de datos se actualiza a diario, agregando imágenes dos días después de que el foro oficial las libere al público.
Propiedades	Banda 1: aerosoles, resolución 60 m Banda 2: azul, resolución 10 m Banda 3: verde, resolución 10 m

	Banda 4: rojo, resolución 10 m Banda 5: borde rojo 1, resolución 20 m Banda 6: borde rojo 2, resolución 20 m Banda 7: borde rojo 3, resolución 20 m Banda 8: NIR, resolución 10 m Banda 8 A: borde rojo 4, resolución 20 m Banda 9: vapor de agua, resolución 60 m Banda 11: SWIR 1, resolución 20 m Banda 12: SWIR 2, resolución 20 m AOT: Densidad óptica de los aerosoles, 20 m WVP: Presión del vapor de agua, 10 m SCL: Mapa de clasificación de escena, 20 m TCI_R: Rojo verdadero, 10 m TCI_G: Verde verdadero, 10 m TCI_B: Azul verdadero, 10 m MSK_CLDPRB: Mapa de probabilidad de nubes, 20 m MSK_SNWPRB: Mapa de probabilidad de nevada, 10 m QA10: Siempre vacío, 10 m QA20: Siempre vacío, 20 m QA60: Máscara de nubes, 60 m
Correcciones	Algoritmos de clasificación de escena Corrección atmosférica

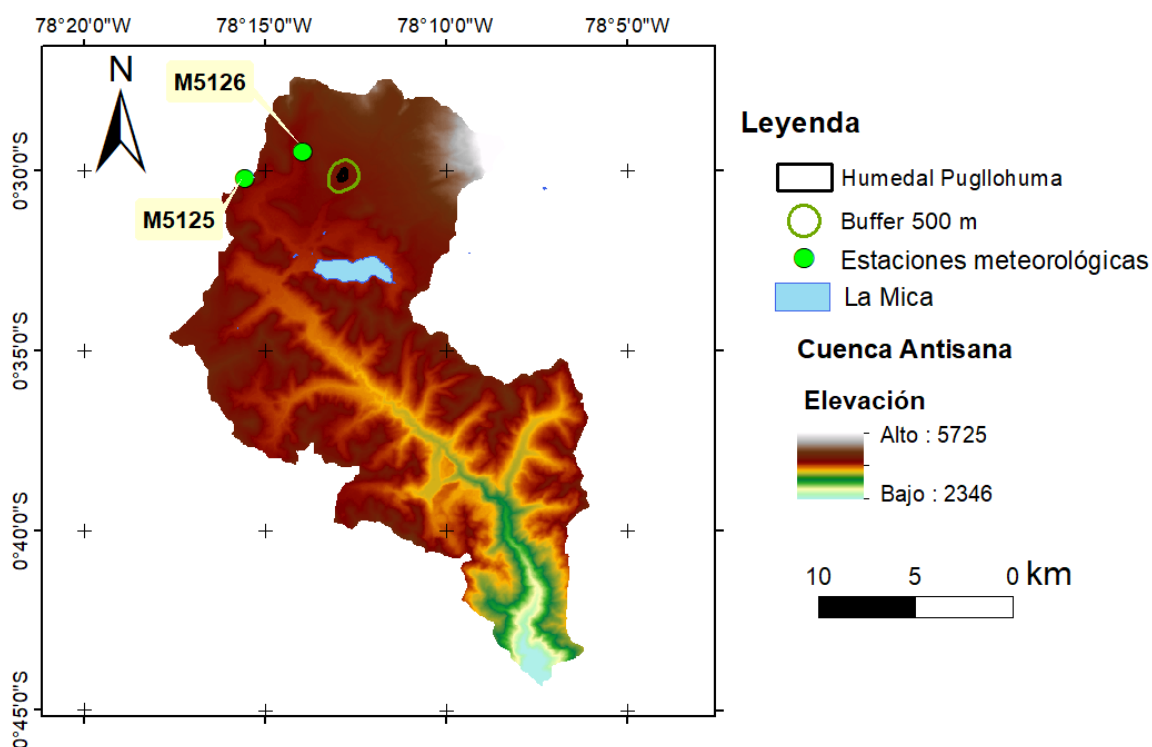
Fuente: ESA, 2015

Elaborado por: Paul David Carchipulla Morales

### 5.1.3. VARIABLES CLIMÁTICAS

Las variables climáticas como la precipitación, humedad relativa y temperatura pueden determinar el nivel de humedad en el suelo (Gabrielsen et al., 2016). Por este motivo, las investigaciones de humedales recomiendan registrar las variaciones climáticas para establecer la dependencia de la recarga del humedal con el incremento o de decremento en alguna de ellas (DeLancey et al., 2018). Entre más variables se puedan registrar se obtendrá mayor cantidad de enfoques de estudio, sin embargo, distintas limitaciones impedirían el monitoreo permanente del área de interés. Además, es necesario elegir meticulosamente las variables para no sobresaturar las modelaciones y reducir la incertidumbre en los resultados.

Cerca del humedal se ha registrado datos meteorológicos a través de las estaciones M5125, y M5126 (Figura 19). Las dos estaciones mencionadas almacenan datos de precipitación, temperatura del aire, humedad relativa del aire, velocidad y dirección del viento, y presión atmosférica. Los datos han sido proporcionados por el Instituto Nacional de Meteorología e Hidrología (INAMHI), y la EPN (Anexo 1). Además, los datos en cuestión fueron solicitados en el periodo desde el 5 de octubre de 2015 hasta el 21 de enero de 2020.



**Figura 19.** Estaciones meteorológicas cerca del humedal Pugllohuma.

Fuente: FONAG, 2016

Estos datos han sido organizados para recibir un tratamiento previo a utilizarlos en la clasificación temporal. Los datos recolectados a una escala horaria fueron transformados a una escala diaria, siguiendo las indicaciones de anuarios meteorológicos del Ecuador (INAMHI, 2012). Esto quiere decir que la precipitación, al ser una variable aditiva, se diferenció del resto para sumar sus registros diarios, mientras el resto de variables obtuvieron un promedio diario. Así mismo, se eliminaron errores de medición registrados por el INAMHI y otros registros atípicos en las mediciones de humedad relativa, presión, temperatura, y viento. Los

registros atípicos o errores de medición se identificaron como outliers en la serie de tiempo y se debieron principalmente a descalibraciones de los equipos.

Cabe mencionar que las estaciones identificadas no mantuvieron el mismo periodo de medición y se encontraban a diferentes distancias del humedal, las cuales son 5 km con respecto a la estación M5125 y 2.4 km con respecto a la estación M5126. Por este motivo, las variables se usaron en una media ponderada entre las dos estaciones para proyectar el clima esperado en el humedal (Wang et al., 1955). En este sentido, el peso que se dio a cada dato fue otorgado por la distancia de la estación con el centro del humedal (Woodcock y Engel, 2005).

## **5.2.RELACIÓN ENTRE LA SATURACIÓN DEL SUELO Y LA RETRODISPERSIÓN DEL RADAR**

Alrededor del planeta se han realizado evaluaciones de la relación entre la retrodispersión captada por S1 y el nivel de saturación del suelo para identificar humedales. Estas evaluaciones comparan los datos medidos del radar con proyecciones o con otra información cuantificable que establezca el nivel de saturación en el humedal (Mattia et al., 2017; Tamm et al., 2016; y Vreugdenhil et al., 2018). Para ello existen diferentes metodologías hacia el reconocimiento de una relación, donde las más usadas son los modelos de regresión lineales, modelos de regresión no lineales, y los modelos de ML (Mattia et al., 2017; Tamm et al., 2016; y Vreugdenhil et al., 2018). En este caso se optó por trabajar con modelos de ML basados en árboles de decisión por la capacidad de trabajar tanto espacial como temporalmente al mismo tiempo, ya que los modelos lineales solamente trabajan espacialmente y los modelos no lineales trabajan temporalmente.

Para los fines de este estudio se aprovechó que las polarizaciones VH y VV, en ese orden, posibilitan la clasificación de áreas de un terreno de menor a mayor nivel de saturación. Por consiguiente, la polarización medida en la imagen fue el filtro utilizado en GEE para escoger las imágenes. El filtro de imágenes en GEE procuró que todas las imágenes contaran con polarizaciones VV y VH, junto con una resolución de 10m x 10m, ya que posteriormente se aplicaría un suavizado de las imágenes como corrección. Las correcciones del speckle fueron realizadas



mediante la técnica ‘focal median’, consistiendo en reducir la resolución de la imagen utilizando medias de los píxeles más cercanos (Santoso et al., 2016; Wong et al., 2019). Para este estudio, se obtuvo una resolución final de 30m x 30m en las imágenes de radar. Además, los estudios más actuales indican que utilizar índices de polarización podrían dar mayores aportes a los modelos de ML (Huang et al., 2018; y Vreugdenhil et al., 2018). Es por esto que la Tabla 10 presenta los índices que han resultado bibliográficamente más útiles al clasificar espacialmente terrenos y fueron calculados para utilizarse en la clasificación.

**Tabla 10.**

*Índices polarizados calculados para las imágenes S1.*

Índice	Abreviatura	Ecuación	Referencia
Relación Polarizada (VH a VV)	VHrVV	$Y_{VHrVV}^0 = Y_{VH}^0 / Y_{VV}^0$	Brisco et al., 2011
Índice de Diferencia Polarizada Normalizada	NDPI	$Y_{NDPI}^0 = \frac{(Y_{VV}^0 - Y_{VH}^0)}{(Y_{VV}^0 + Y_{VH}^0)}$	Mitchard et al., 2012
Índice VH Normalizado	NVHI	$Y_{NVHI}^0 = (Y_{VH}^0) / (Y_{VV}^0 + Y_{VH}^0)$	McNairn y Brisco, 2004
Índice VV Normalizado	NVVI	$Y_{NVVI}^0 = (Y_{VV}^0) / (Y_{VV}^0 + Y_{VH}^0)$	McNairn y Brisco, 2004

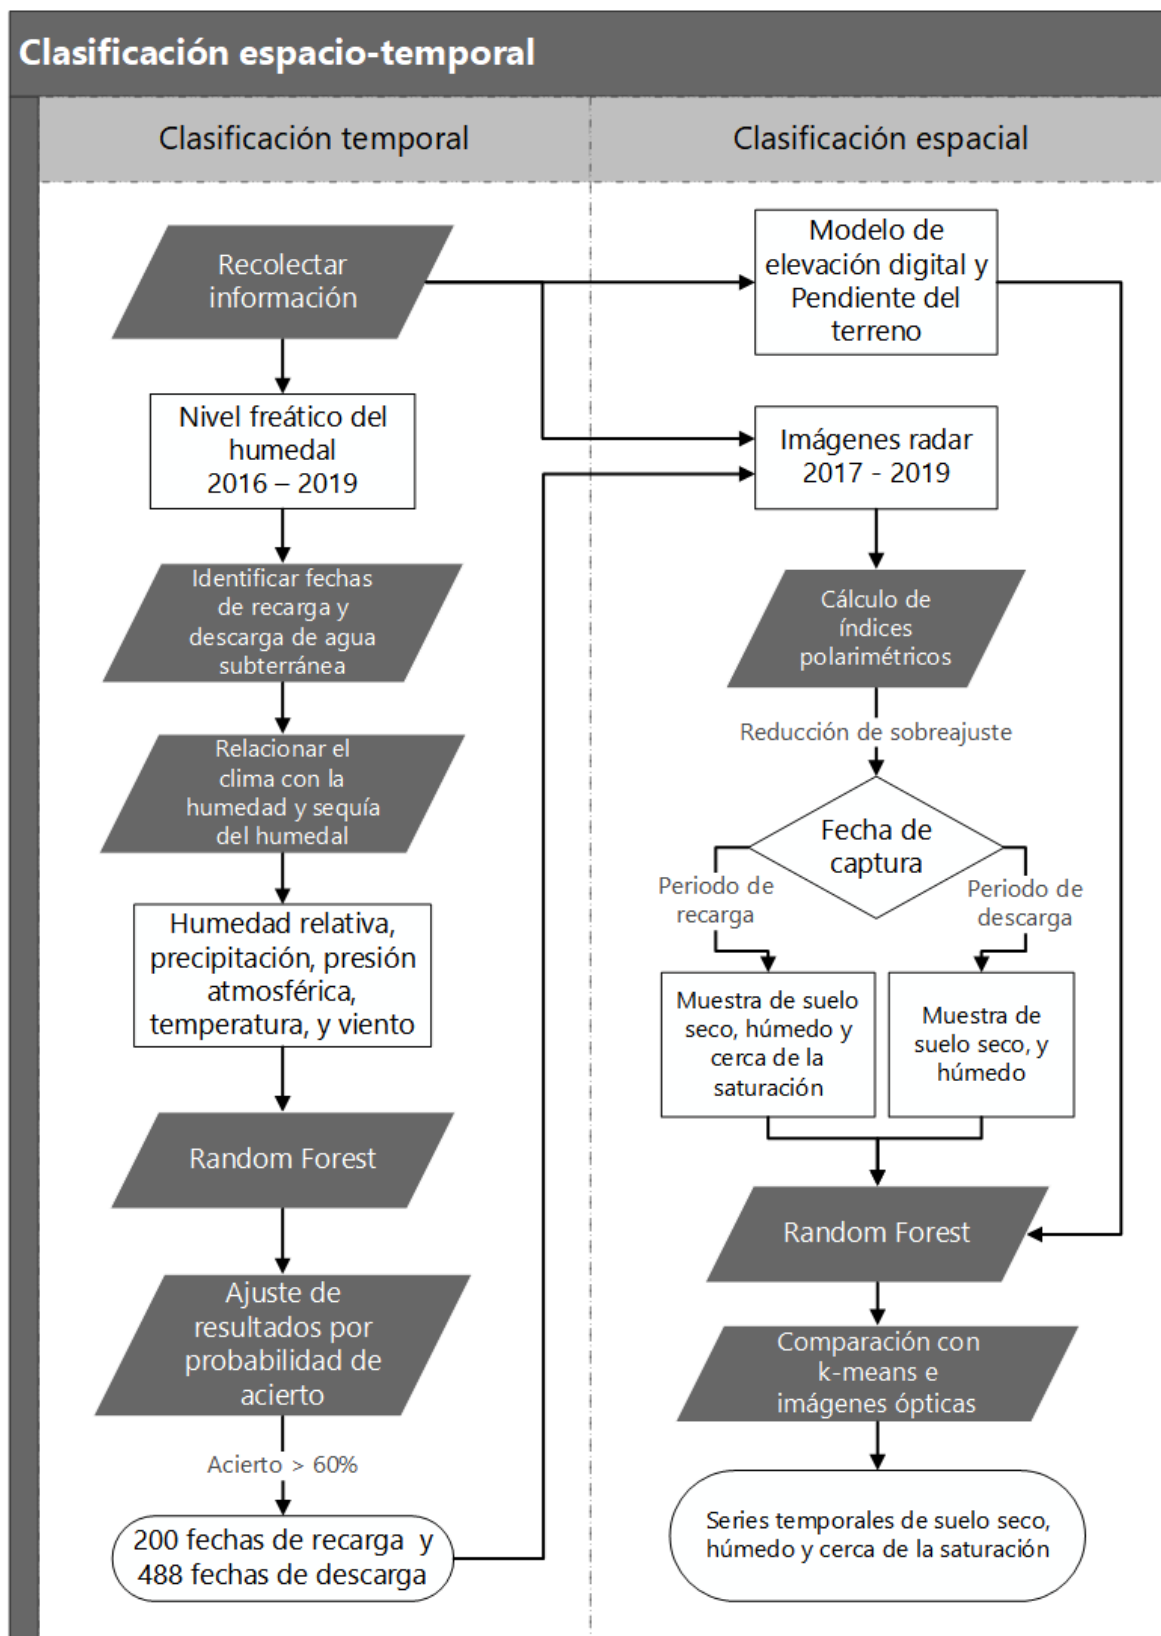
Fuente: Huang et al., 2018

### 5.3. CLASIFICACIÓN SUPERVISADA

El proceso de la clasificación supervisada se muestra en la Figura 20. El diagrama de proceso distingue dos partes esenciales: la clasificación temporal y la clasificación espacial. Inicialmente, la clasificación temporal se desarrolla individualmente para clasificar los periodos de mayor y menor saturación en el humedal (Schumacher y Klesschulte, 2010; Shepherd y Water, 2009; y Taylor y Alley, 2001). Posteriormente, los periodos clasificados fueron utilizados para la búsqueda de imágenes SAR. De este modo, la retrodispersión medida por S1 fue relacionada con la saturación o sequía del humedal. Finalmente, los datos de retrodispersión y periodo del año junto la información de elevación y pendiente, se usan para clasificar el nivel de saturación en el área de estudio desde el año 2017 al 2019.

La clasificación supervisada temporal fue llevada a cabo mediante el software estadístico R y aplicando el paquete de RF. La clasificación temporal utilizó los niveles freáticos en los pozos para identificar las fechas de saturación del suelo del humedal. Seguido, la información meteorológica se agregó a las fechas con información de nivel freático. Aquellas fechas ya identificadas dentro del periodo de recarga o descarga se usaron como muestra de la clasificación al agregar una variable discreta que represente el periodo en el que se encuentran. Posterior a la aplicación, se utilizó la probabilidad de acierto en las clasificaciones de cada dato para reducir errores en los resultados.

Por otro lado, la clasificación supervisada espacial se realizó en la plataforma GEE, bajo un lenguaje de programación que combina Python y Javascript para realizar análisis geoestadísticos (Gorelick, 2016). El paquete de clasificación supervisada de GEE incluye algoritmos de ML como CART, Random Forest, NaiveBayes y SVM (Gorelick, 2016). De entre los algoritmos de ML de GEE se escogió a RF por la alta eficiencia que tiene el algoritmo al aprender correspondencias entre datos de entrada y resultado a predecir, así como la cantidad de bibliografía que existe de su aplicación en monitoreos ambientales (Gabrielsen et al., 2016; Jara et al., 2019; y Ros y Guillaume, 2020). La clasificación espacial requirió de muestras de áreas que describan diferentes niveles de saturación dentro del área de interés (Podest y McCartney, 2019). Las muestras dentro del área de interés recopilaron información de índices polarimétricos, elevación, pendiente, el día del año de captura de la imagen, y el ángulo de captura (Huang et al., 2018). Seguido, se evaluó la importancia de las variables en R mediante la cantidad de errores que surgen en el modelo por su ausencia o presencia, y se seleccionó las más relevantes para la aplicación en GEE. Por último, se comparó los resultados con una clasificación no supervisada con imágenes ópticas de S2 en GEE (Ahmed y Akter, 2017; Tsyganskaya et al., 2018). La descripción de los pasos realizados durante ambas clasificaciones se presenta en los siguientes títulos.



**Figura 20.** Clasificación espacio-temporal del humedal Puglluhuma.

Elaborado por: Paul David Carchipulla Morales

### 5.3.1. MUESTREO DE LA CLASIFICACIÓN SUPERVISADA TEMPORAL

El éxito en la construcción de un modelo de clasificación supervisada se debe en mayor parte a la selección de datos de entrenamiento o muestreo como se ha denominado en este estudio (Gorelick, 2016). Las variables continuas como los registros meteorológicos son eficaces al realizar modelos de clasificación temporal con el objetivo de determinar estacionalidades climáticas (Ros y Guillaume, 2020). En este caso, los niveles freáticos medidos en el humedal sirvieron para identificar días de sequía y saturación con agua en el área de estudio. De esta manera, se pudo construir una muestra de mediciones climáticas para la construcción del modelo de clasificación supervisada temporal.

Para identificar días de sequía y saturación con agua en el humedal se utilizó un umbral definido por los percentiles de los registros de nivel freático en cada pozo ubicado en el humedal. Los percentiles establecieron que dentro del tercer y primer cuartil se encuentra la mayor cantidad de mediciones. Por lo tanto, esta observación puede utilizarse para definir tanto el umbral de recarga como el de descarga en el humedal (Berry et al., 2019; Hunt et al., 2004; y Myers et al., 1999). Para esto se utilizó el valor medio del tercer cuartil y primer cuartil de cada pozo, para luego graficarlos frente a un scatterplot del nivel freático registrado por cada pozo. La media del tercer cuartil definió a que nivel freático empieza el periodo de recarga en el humedal, mientras la media del primer cuartil definió el nivel freático en el que se da la descarga hídrica (Schumacher y Klesschulte, 2010; Shepherd y Water, 2009b; y Taylor y Alley, 2001). Esta metodología resulta ser efectiva, ya que tanto el umbral de recarga como de descarga abarcan los picos de aumento y disminución de nivel freático en el humedal.

De este modo, se construyó una matriz con la muestra de la clasificación supervisada temporal para ser utilizada en el entrenamiento del modelo de clasificación. En este sentido, el formato de la matriz utilizada para ingresar la muestra en la construcción del modelo es presentado en la Tabla 11. En la tabla mostrada a continuación se puede apreciar que las primeras 7 columnas contienen la información climática y temporal utilizada para la clasificación, mientras que para diferenciar entre las muestras de los días de recarga y descarga se utilizó la variable

discreta Clase. La variable Clase contiene los números 0 y 1 como factores, donde 0 etiqueta a los datos de un día dentro del periodo de recarga y 1 a los datos de un día dentro del periodo de descarga.

**Tabla 11.**

*Modelo de la matriz de muestras para la clasificación supervisada temporal.*

Humedad Relativa (%)	Presión atmosférica (mbar)	Precipitación (mm)	Temperatura (°C)	Dirección del Viento (°)	Velocidad del Viento (m·s-1)	Día del año	Clase
94.41	623.67	2.32	3.33	259.99	3.58	100	1
94.32	623.77	1.56	3.71	272.18	3.70	101	0

Elaborado por: Paul David Carchipulla Morales

### 5.3.2. CONSTRUCCIÓN Y ENTRENAMIENTO DE LA CLASIFICACIÓN SUPERVISADA TEMPORAL

Durante la etapa de construcción y entrenamiento se trabajó con el objetivo de definir los parámetros más importantes con los cuales trabajar en el modelo de RF (Breiman et al., 2018). Para iniciar la construcción del modelo de clasificación supervisada temporal se abrevió el nombre de las variables a utilizar para evitar errores durante la programación del modelo. La Tabla 12 muestra el símbolo correspondiente a las variables del modelo de clasificación supervisada temporal.

**Tabla 12.**

*Símbolos asignados a variables del modelo temporal.*

SÍMBOLO	SIGNIFICADO
DOY	Día del año
HR	Humedad Relativa
PA	Presión Atmosférica
PRECIP	Precipitación
T	Temperatura
WD	Dirección del viento
WS	Velocidad del viento

Elaborado por: Paul David Carchipulla Morales

El primer paso para la construcción del modelo temporal fue la cuantificación de la correlación entre variables, calculando la colinealidad de ellas y grificándola con la función `corrplot` (Wei et al., 2017). Si las variables mostraran colinealidad, una de las variables solo estaría retardando al algoritmo pues no favorece a diferenciar entre clases (Devore, 2018; y Hariharan et al., 2018). En general, las variables son definidas como colineales cuando la correlación entre ellas es mayor a 0.4 (Devore, 2018; y Hariharan et al., 2018). En ese caso sería necesario seleccionar una de las variables colineales y desechar el resto.

Lo siguiente, es definir el número de árboles de decisión a generar porque el algoritmo RF toma muestras al azar de los datos y realiza una clasificación, repitiéndose tantas veces como árboles de decisión, para finalmente seleccionar como resultado aquel que se haya obtenido con mayor frecuencia entre los árboles (Breiman et al., 2018). En este aspecto, se encuentra un error conocido como Out of Bag (OOB) que se refiere a la discrepancia entre los árboles de decisión (Behnamian et al., 2017). Para reducirlo, se mide el error frente a diferentes números de árboles de decisión y se elige un punto en el que dicho error sea mínimo o se estabilice. La construcción de una curva OOB vs Árboles de decisión se la realizó a partir del paquete `Ranger`, que es una versión reducida de RF utilizada en procesos menores de la construcción de modelos de clasificación (Wright et al., 2020).

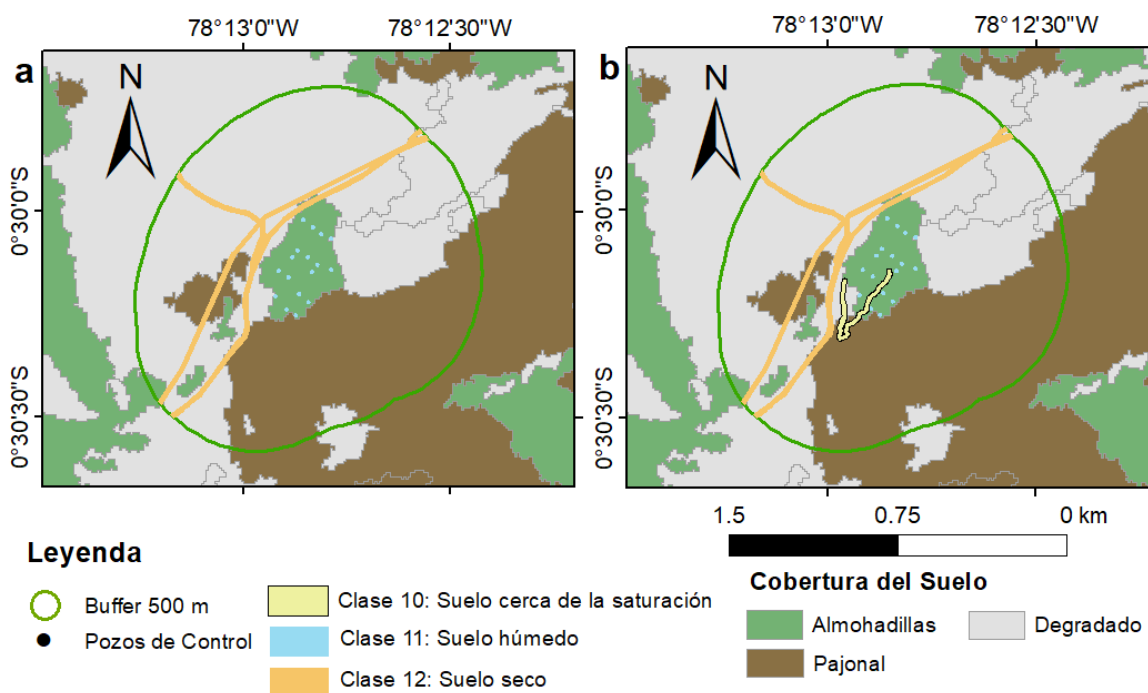
También se aprovechó que el paquete RF en R Studio permite seleccionar variables para evitar alteraciones en la clasificación a partir del cálculo del Mean Decrease Accuracy (MDA) y el Mean Decrease Gini Index (MDG) (Han et al., 2016). El primero mide la importancia de las variables y el segundo mide la impureza de las mismas. El MDA realiza la medición a través del cambio en el éxito de la clasificación cuando la variable analizada es descartada, en tanto el MDG suma todas las reducciones en errores que genera la variable en la clasificación (Behnamian et al., 2017; y Hariharan et al., 2018).

### **5.3.3. EVALUACIÓN DE LA CLASIFICACIÓN SUPERVISADA TEMPORAL**

El algoritmo de RF clasificó dentro del periodo de recarga a las fechas que en más del 50% de los árboles de decisión se obtuviera el mismo resultado, y lo mismo sucedió con las fechas clasificadas dentro del periodo de descarga (Breiman et al., 2018). Este porcentaje que usa RF para definir clases se conoce como porcentaje de acierto (Sullivan, 2017). En este sentido, la evaluación del modelo temporal consistió en identificar un porcentaje de acierto en la clasificación que mantuviera una similitud con la descripción estacional mediante series de tiempo realizada en este estudio y en estudios anteriores. La descripción estacional de la saturación con agua del suelo del humedal ha definido el periodo seco entre los meses de enero, febrero, julio, agosto y septiembre, mientras los periodos húmedos ocurren de abril a junio y de octubre a diciembre (Espinel 2019; y Palma 2020). De este modo, se visualizó la distribución temporal de la probabilidad de acierto de la clasificación y se identificó el umbral donde las fechas presentaban una estacionalidad marcada que se ajustara a la mencionada anteriormente.

### **5.3.4. MUESTREO DE LA CLASIFICACIÓN SUPERVISADA ESPACIAL**

La construcción de la muestra de clasificación espacial usó imágenes de radar en las fechas de recarga y descarga del humedal indicadas en la clasificación temporal. En ellas se tomó datos de las características de vuelo de imágenes radar, retrodispersión, índices polarimétricos, así como elevación del terreno y pendiente. La información tomada de las imágenes fue recuperada de tres áreas: las vías de acceso, los pozos, y el área de drenaje principal; siendo interpretadas como áreas secas, húmedas, y cerca de la saturación, respectivamente. Cabe mencionar que para recuperar la información de las áreas mencionadas fue necesario construir dos polígonos a partir de áreas de influencia con un radio de 10 m alrededor de líneas y puntos que representaban las vías de acceso, pozos de control freático y cauce de descarga en el humedal. Estos polígonos se crearon para homogenizar el formato de figuras, unir las, y facilitar la toma de muestras en las imágenes (Schwert et al., 2018; Figura 21).



**Figura 21.** Muestreo espacial para clasificación supervisada. Figura a) Áreas de muestra en el periodo seco. Figura b) Áreas de muestra en el periodo húmedo.

Fuente: FONAG, 2019

Elaborado por: Paul David Carchipulla Morales

La diferencia entre los polígonos construidos para tomar la muestra de las imágenes radar fue la presencia del cauce de descarga en el humedal. Esta diferencia entre polígonos de muestra fue necesaria porque la recolección de datos en el cauce de descarga durante el periodo seco sobreajustaba el modelo de clasificación supervisada. Es decir, los datos recuperados del área de descarga en el periodo seco no mostraban patrones que facilitaran la clasificación de zonas en las imágenes radar y el modelo se volvía demasiado complejo para describir el área de interés (Ramkumar et al., 2015; y Whyte et al., 2018). En este sentido, durante el periodo de descarga se utilizó las vías de acceso y los pozos de drenaje para recuperar información del terreno, ya que al ser un periodo seco no existiría un área de drenaje que pueda ser captada por S1 ni interpretada por RF (Figura 21a). Por otro lado, durante el periodo de recarga se utilizó las vías de acceso, los pozos, y el área de drenaje para recuperar la información espacial del terreno (Figura 21b). Adicionalmente, durante esta etapa se agregó una variable de clase factor a cada pixel de las imágenes para realizar la clasificación espacial y describir el nivel de



saturación del terreno. En esta ocasión se utilizaron números de dos cifras para definir clases espaciales y no sean confundidas con las clases temporales, por lo cual, el número 10 representó al suelo cerca de la saturación, el número 11 al suelo húmedo, y el número 12 al suelo seco.

De este modo se recuperó información espacial de cada imagen radar dentro de los periodos de recarga y descarga definidos en la clasificación supervisada temporal. La Tabla 13 muestra un ejemplo de la matriz que se construyó con la muestra de la clasificación supervisada espacial para ser utilizada en el entrenamiento del modelo de clasificación. La siguiente matriz muestra información de elevación, día del año, retrodispersión, índices polarimétricos utilizados en la teledetección de agua de acuerdo a la Tabla 10, ángulo de captura de la imagen radar, pendiente del terreno, y la clasificación del terreno. La descripción de los símbolos de las variables está en la Tabla 14.

**Tabla 13.**

*Modelo de la matriz de muestras para la clasificación supervisada espacial.*

DEM (msnm)	Día del Año	NDPI	NVHI	NVVI	VH (db)	VHrVV	VV (db)	Ángulo (°)	Slp (%)	Clase
4132	37	0.19	0.59	0.41	23.0	1.46	15.8	43.06	3.1	11
4143	321	0.26	0.63	0.37	25.9	1.71	15.2	43.01	14	12
4119	138	0.41	0.70	0.30	24.3	2.38	10.2	33.88	3.1	10

Elaborado por: Paul David Carchipulla Morales

### **5.3.5. CONSTRUCCIÓN Y ENTRENAMIENTO DE LA CLASIFICACIÓN SUPERVISADA ESPACIAL**

La construcción del modelo de clasificación supervisada espacial fue realizada en R para reducir la cantidad de trabajos a realizar en GEE y de este modo aprovechar el servidor en la aplicación de la clasificación supervisada a las imágenes radar; por ejemplo, al simplificar la información utilizada con indicadores de significancia y medir la correlación de variables se pudo incluir en la presentación de resultados en GEE series de tiempo del cambio el contenido de agua en el suelo (Han et al., 2016).

Además, la construcción del modelo espacial siguió pasos similares a los que se usaron en la construcción del modelo temporal, a excepción del cálculo de árboles de decisión a utilizar en el modelo debido a que el tiempo de procesamiento en el servidor limitó al estudio a utilizar 100 árboles. En este sentido, tras abreviar los nombres de las variables espaciales, la construcción y entrenamiento del modelo de clasificación consistió en evaluar la colinealidad de las variables a utilizar, y medir la importancia de las variables durante la clasificación. Así como en el modelo de clasificación supervisada temporal, los nombres de las variables espaciales fueron abreviados para trabajar durante la programación del modelo (Tabla 14).

**Tabla 14.**

*Símbolos asignados a variables del modelo espacial.*

SÍMBOLO	SIGNIFICADO
DEM	Elevación sobre el nivel del mar
DOY	Día del año
NDPI	Índice de Diferencia Polarizada Normalizada
NVHI	Índice VH Normalizado
NVVI	Índice VV Normalizado
VH_S	Polarización vertical-horizontal suavizada (30 m)
VHrVV	Relación Polarizada (VH a VV)
VV_S	Polarización vertical-vertical suavizada (30 m)
Angle	Ángulo de captura de retrodispersión
slp	Pendiente del terreno

Elaborado por: Paul David Carchipulla Morales

### **5.3.6. EVALUACIÓN DE LA CLASIFICACIÓN SUPERVISADA ESPACIAL**

Al evaluar la clasificación espacial se buscó la relación entre el resultado supervisado y no supervisado (Ahmed y Akter, 2017; y Amani et al., 2019). La comparación entre una clasificación supervisada utilizando imágenes SAR y una clasificación no supervisada mediante imágenes ópticas ha demostrado un nivel de concordancia aceptable. La clasificación no supervisada con k-means opera mediante una agrupación de clases semejantes (Naghdy et al., 2014). La agrupación de clases semejantes permitió que se valore la representatividad de las áreas de muestra en la clasificación supervisada y el acierto en los resultados. Es

así que se optó por trabajar con imágenes S2 para evaluar la confiabilidad de la clasificación de S1 (Mahdianpari et al., 2019). En este sentido, se utilizó una clasificación no supervisada en imágenes S2 que se hayan recuperado en una fecha igual o con tres días de diferencia con las imágenes S1. Para ello, se calcularon los índices espectrales mostrados en la siguiente tabla y posteriormente se calculó su colinealidad. Los siguientes índices han sido utilizados anteriormente en estudios de humedales en los Andes (Jara et al., 2019).

**Tabla 15.**

*Índices espectrales calculados para las imágenes S2.*

Índice	Abreviatura	Ecuación	Referencia
Índice de Vegetación de Diferencia Normalizada	NDVI	$NDVI = \frac{NIR - RED}{NIR + RED}$	Rouse et al., 1974
Índice de Agua de Diferencia Normalizada	NDWI	$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$	GAO, 1996
Índice Modificado de Agua de Diferencia Normalizada	MNDWI	$MNDWI = \frac{GREEN - RED}{GREEN + RED}$	Xu, 2006
Índice de Vegetación de Rango Dinámico Amplio	WDRI	$WDRI = \frac{0.05 * NIR - RED}{0.05 * NIR + RED}$	Gitelson, 2004
Índice de Vegetación Mejorado 2	EVI2	$EVI2 = \frac{2.5 * (NIR - RED)}{(NIR + 2.4) * (RED + 1.0)}$	Jiang et al., 2008
Red Edge Model	RE	$RE = \frac{NIR}{RED - 1}$	Gitelson et al., 2005

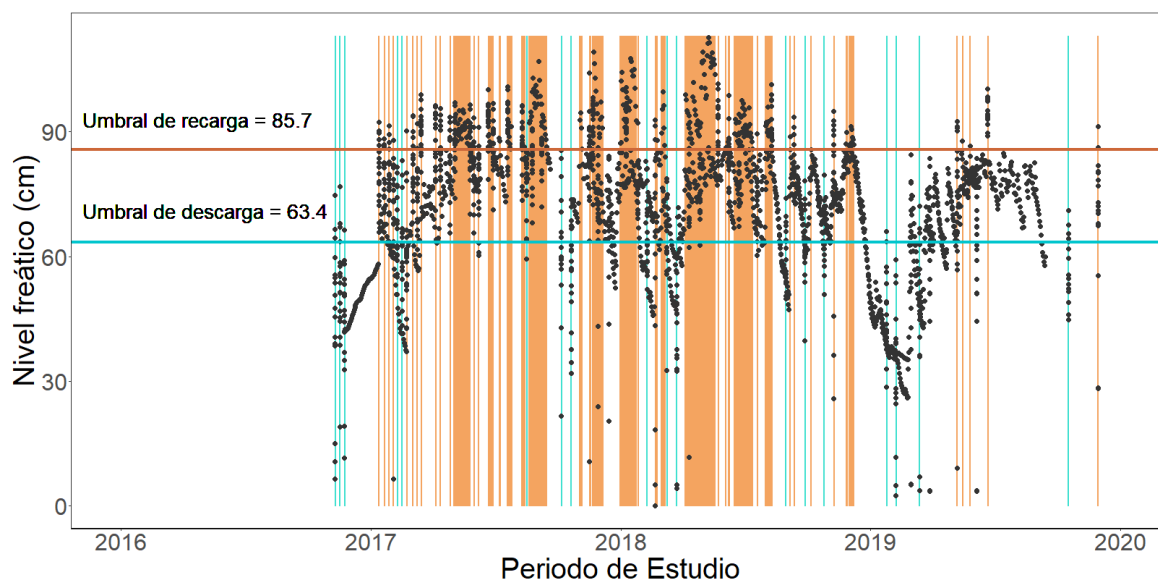
Fuente: Jara et al., 2019; Pena-Regueiro et al., 2020; Rokni et al., 2014

Cada imagen óptica tomó muestras dentro de las mismas áreas que se usaron en la clasificación supervisada para que el algoritmo diferencie por sí mismo tres clases dentro del humedal (Gulácsi y Kovács, 2020). A diferencia de la clasificación supervisada, no se le indicó al algoritmo cuáles son las tres clases que debe encontrar, sino que el equipo las identifica por sí mismo. Esta es una práctica común que suele hacerse manualmente con distribuciones de indicadores de clasificación (Naghdy et al., 2014; y Podest y McCartney, 2019).

## CAPÍTULO 6. RESULTADOS Y DISCUSIÓN

### 6.1. PERIODOS DE SATURACIÓN

El tercer cuartil de los datos de nivel freático del humedal coincide con la época húmeda en los meses de abril a junio y de octubre a diciembre. Así mismo, el primer cuartil de datos de nivel freático coincide con la época seca en los meses de enero, febrero, julio, agosto y septiembre. En los registros de nivel freático se identificaron 243 días dentro del periodo de recarga entre enero de 2017 y noviembre de 2019, así como 285 días dentro del periodo de descarga desde noviembre de 2016 a noviembre de 2019. Sin embargo, solamente 87 días en el periodo de recarga y 128 días en el periodo de descarga contaban con información climática. Por otro lado, el resto de días con información del nivel freático se consideraron como días de transición y no se utilizaron para crear la muestra del modelo temporal. De este modo, la Figura 22 muestra con color naranja los periodos de recarga en el humedal con nivel freático mayor a 85.7 cm. Por otra parte, la descarga del humedal se registra en los niveles freáticos menores a 63.4 cm, y este umbral se visualiza con una línea de color celeste. Además, en la Figura 22 se representa los días de recarga y descarga con los colores naranja y celeste, respectivamente.

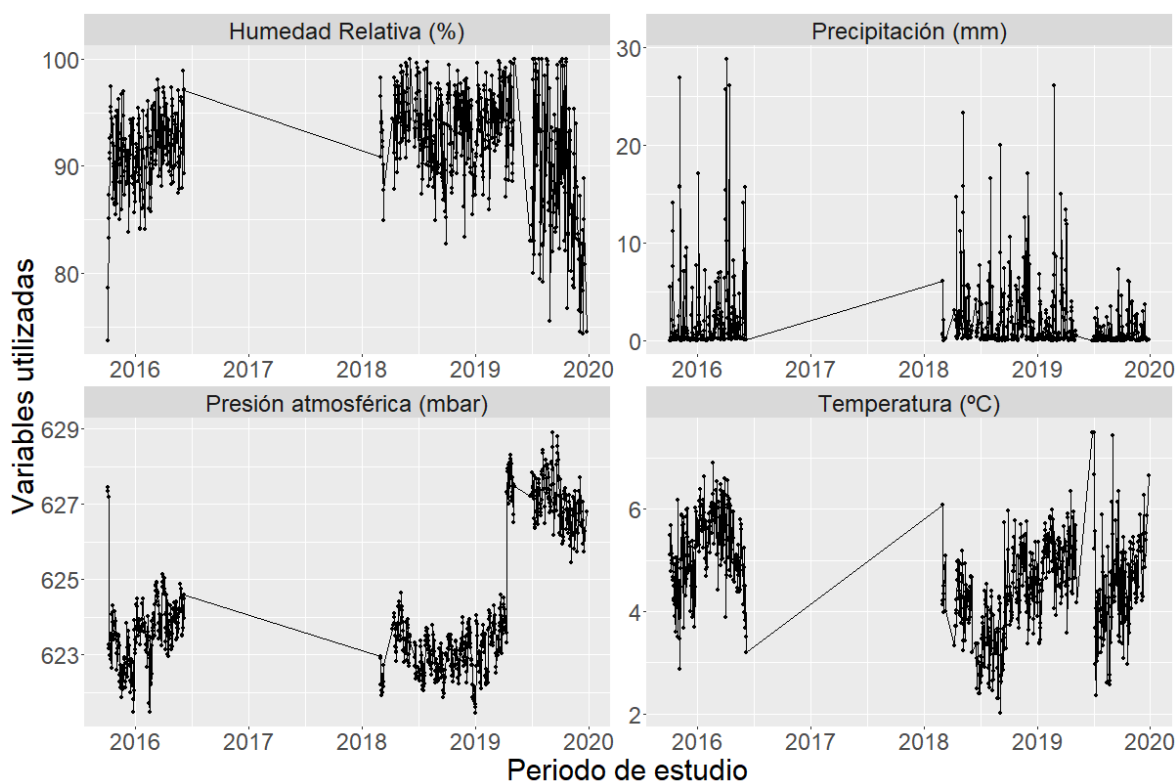


**Figura 22.** Distribución temporal del nivel freático en el humedal.

Fuente: FONAG, 2019

Elaborado por: Paul David Carchipulla Morales

También es posible visualizar la estacionalidad del humedal en las variables climáticas obtenidas con la media ponderada de las estaciones M5125, y M5126. (Anexo 1; Figura 23; y Figura 24). Por tanto, una de las primeras observaciones en la Figura 23 es que la precipitación marca los meses húmedos por un aumento en la frecuencia de eventos de lluvia superiores a los 10 mm/día desde abril a junio y de octubre a diciembre como se describió en el Capítulo 4. Área de estudio (Figura 23). Análogamente, la humedad relativa mantiene una relación directa con la precipitación, mientras la presión atmosférica tiene una relación inversa con la humedad relativa y la precipitación, y estas relaciones son más evidentes entre finales del año 2019 e inicios del año 2020. Ahora bien, la serie temporal de la temperatura entre 2016 y 2020 indica un cambio interanual que denota la ausencia de una estacionalidad definida para esta variable. De este modo, la mayor saturación con agua en el suelo del humedal fue asociada visualmente a los días con 10 mm/día de precipitación, 94% de humedad relativa, 623 mbar de presión atmosférica y temperaturas de 5 °C.

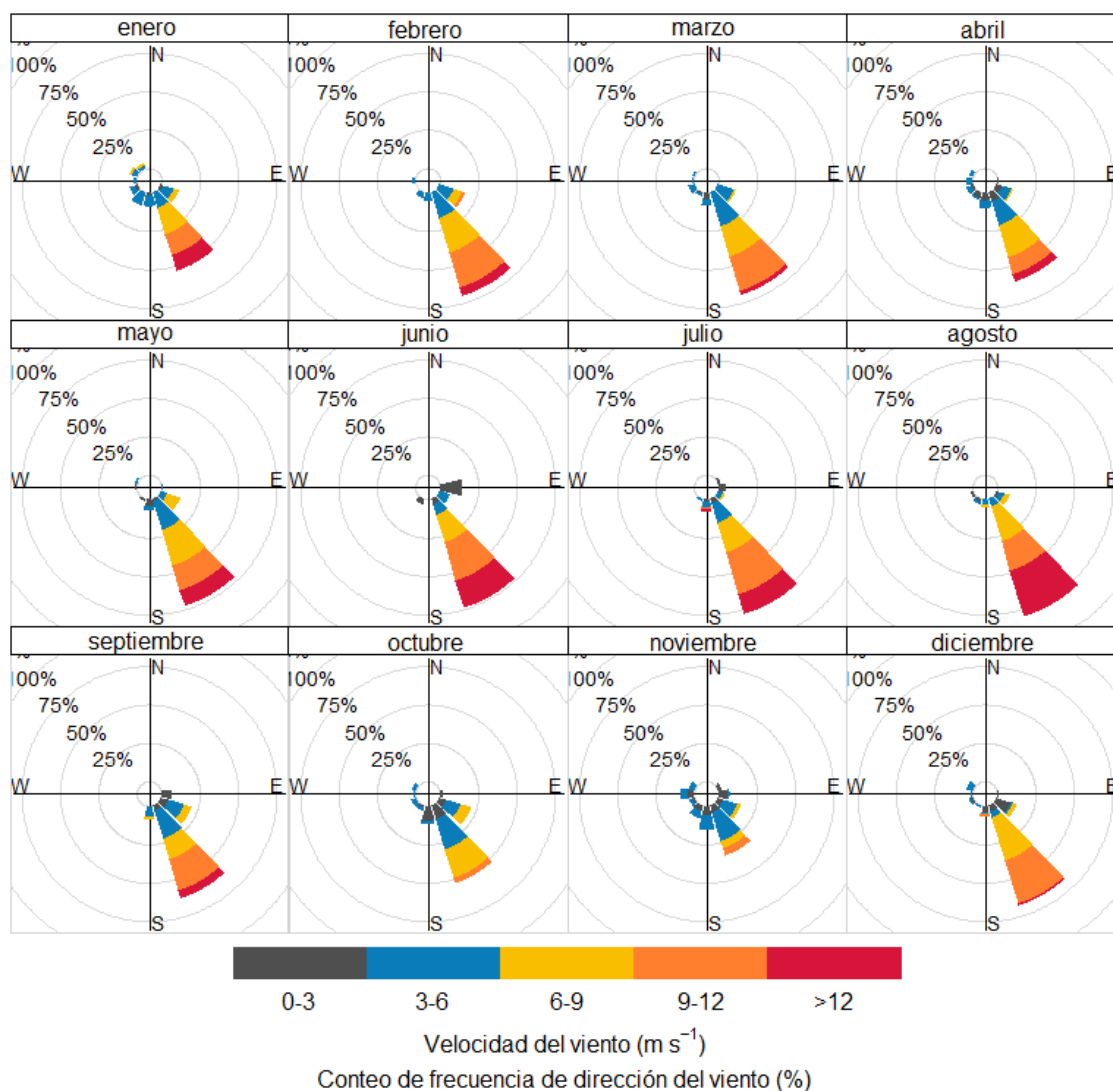


**Figura 23.** Ponderación de datos climáticos en el humedal de 2016 a 2020.

Fuente: Páez-Bimos, 2018; FONAG, 2019; INAMHI, 2020

Elaborado por: Paul David Carchipulla Morales

Al evaluar la estacionalidad del viento entre 2016 y 2020 se pudo distinguir que la dirección del viento provenía del sur durante la mayor parte del año y que fueron más frecuentes las velocidades de viento diarias menores a los 7 m/s (Figura 24). Aun así, la velocidad del viento puede superar 15 m/s con más frecuencia en los meses de enero, mayo, junio, julio, y agosto. Por otra parte, el mes de noviembre demuestra una caída en la velocidad del viento con respecto a los otros meses del año y las corrientes del viento son más dispersas espacialmente. La disminución en la velocidad del viento en noviembre coincide con la segunda crecida en la precipitación descrita en el Capítulo 4. Área de estudio (Figura 14).




**Figura 24.** Ponderación mensual de viento en el humedal de 2016 a 2020.

Fuente: Páez-Bimos, 2018; FONAG, 2019; INAMHI, 2020

Elaborado por: Paul David Carchipulla Morales

## 6.2.GRÁFICAS DE REPRESENTATIVIDAD DE VARIABLES TEMPORALES

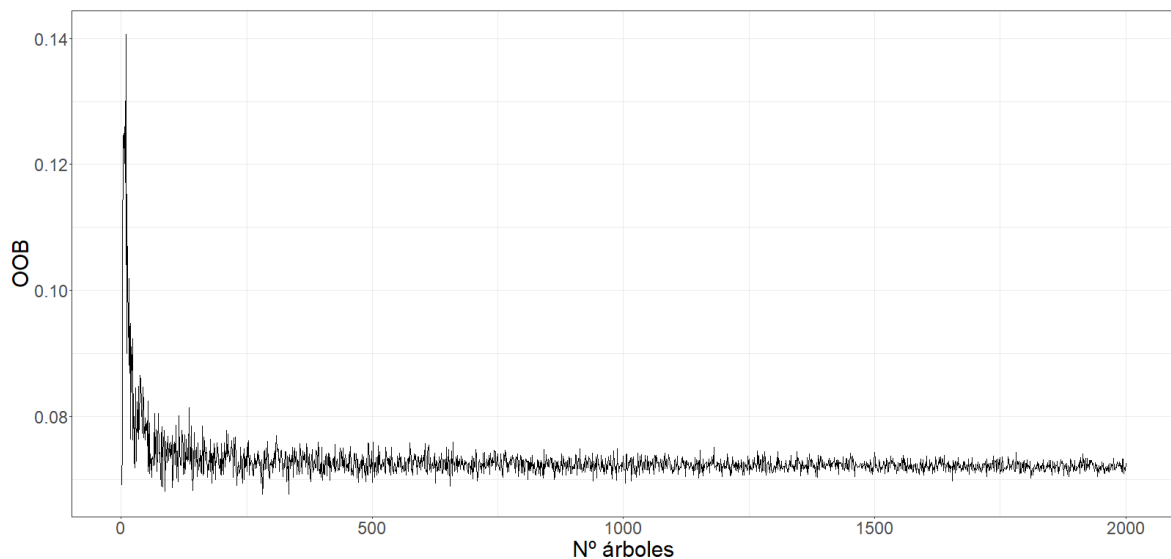
La matriz de correlación entre variables temporales mostró magnitudes entre 0.35 y -0.47 (Figura 25). La velocidad del viento (WS) presentó sus mayores correlaciones en un sentido inverso con la precipitación (PRECIP), presión atmosférica (PA), y temperatura (T). Entre las correlaciones de la velocidad del viento se presentó la mayor correlación inversa igual a -0.47, entre dicha variable y la presión atmosférica. Por tanto, la variable velocidad del viento fue descartada al mostrar una colinealidad inversa menor a -0.4 con la variable presión atmosférica (Devore, 2018; Hariharan et al., 2018). En el caso de las correlaciones positivas, la mayor fue registrada entre la humedad relativa (HR) y la precipitación con un valor de 0.35.



**Figura 25.** Correlación de variables de clasificación temporal.

Elaborado por: Paul David Carchipulla Morales

Por otro lado, la Figura 26 muestra como a mayor número de árboles, hay menor variación en los resultados de clasificación con respecto a la muestra ingresada. En este sentido, las variables temporales usadas en la proyección del número óptimo de árboles definieron que alrededor de los 1250 árboles existen menos errores en los resultados. Los 1250 árboles muestran una fracción de error de aproximadamente 0.07 en las clasificaciones de datos conocidos, y se usó este dato dentro del modelo.




**Figura 26.** Curva OOB vs árboles de decisión en clasificación temporal.

Elaborado por: Paul David Carchipulla Morales

En cambio, la Figura 27 presenta la importancia de las variables durante la clasificación y decrecimiento de impurezas en el modelo de clasificación supervisada por la presencia de dichas variables. Al medir la importancia de las variables dentro de la clasificación se observó que las variables relevantes para el modelo son el día del año (DOY), presión atmosférica (PA) y temperatura (T). Tanto el MDA como el MDG del día del año son superiores a 0.15, de modo que la variable día del año resultó ser hasta tres veces más importante en comparación con las variables medianamente importantes como la precipitación, y presión atmosférica (Figura 27). Las variables medianamente representativas varían su nivel de importancia entre los índices MDA y MDG. La variación de importancia de la precipitación, presión atmosférica, y humedad relativa se encuentra alrededor de 0.03. Por otro lado, la dirección del viento se mantiene como la menos importante



de acuerdo al MDA y el MDG con valores inferiores a 0.02. Aun así, ninguna variable fue descartada por la importancia que han mostrado al influir en el desarrollo temporal en otras clases de humedales (Lasso et al., 2014; y Wong et al., 2019).




**Figura 27.** Importancia e impurezas de variables en clasificación temporal.

Elaborado por: Paul David Carchipulla Morales

### 6.3. GRÁFICAS DE REPRESENTATIVIDAD DE VARIABLES ESPACIALES


La construcción del modelo de clasificación espacial trabajó de manera similar al de la clasificación temporal. Entre las variables espaciales analizadas, se obtuvo una correlación fuerte entre los índices polarimétricos y la retrodispersión medida por el sensor radar. Las correlaciones entre los índices polarimétricos y la retrodispersión mostraron ser casi perfecta con valores muy cercanos a 1 y -1 (Figura 28). Por tal motivo, se procedió a descartar los índices polarimétricos del modelo.



**Figura 28.** Correlación de variables en clasificación espacial.

Elaborado por: Paul David Carchipulla Morales


Tras descartar los índices polarimétricos se redujeron las correlaciones a valores entre 0.43 y -0.38 (Figura 29). Por consiguiente, la correlación positiva más significativa está dada por la polarización horizontal (VH\_S) y vertical (VV\_S) con un valor de 0.43. A pesar de eso, no se descartó ninguna por las ventajas espaciales que aportan las polarizaciones al diferenciar los niveles de saturación en el suelo (Gabrielsen et al., 2016). En cambio, las correlaciones negativas más significativas se reflejan en las relaciones entre las polarizaciones y el ángulo de captura de imagen, las cuales se mantienen con magnitudes menores a 0.4.



**Figura 29.** Nueva correlación de variables en clasificación espacial.

Elaborado por: Paul David Carchipulla Morales

Posteriormente, la importancia de las variables espaciales se evaluó con un modelo simplificado de clasificación supervisada que utilizó 100 árboles de decisión. Entonces resulta que la elevación del terreno (DEM) y ángulo de captura son las variables más relevantes en el modelo, mientras la variable día del año (DOY) es la menos relevante. Por otra parte, la pendiente (slp) resultó ser medianamente relevante para el modelo, pero reduce importantemente la impureza de los resultados. En cambio, las polarizaciones muestran una importancia y media, mientras reducen medianamente las impurezas de los resultados. De este modo, el MDA y MDG indican que todas las variables estudiadas en esta sección tienen ventajas para el modelo de clasificación supervisada espacial.

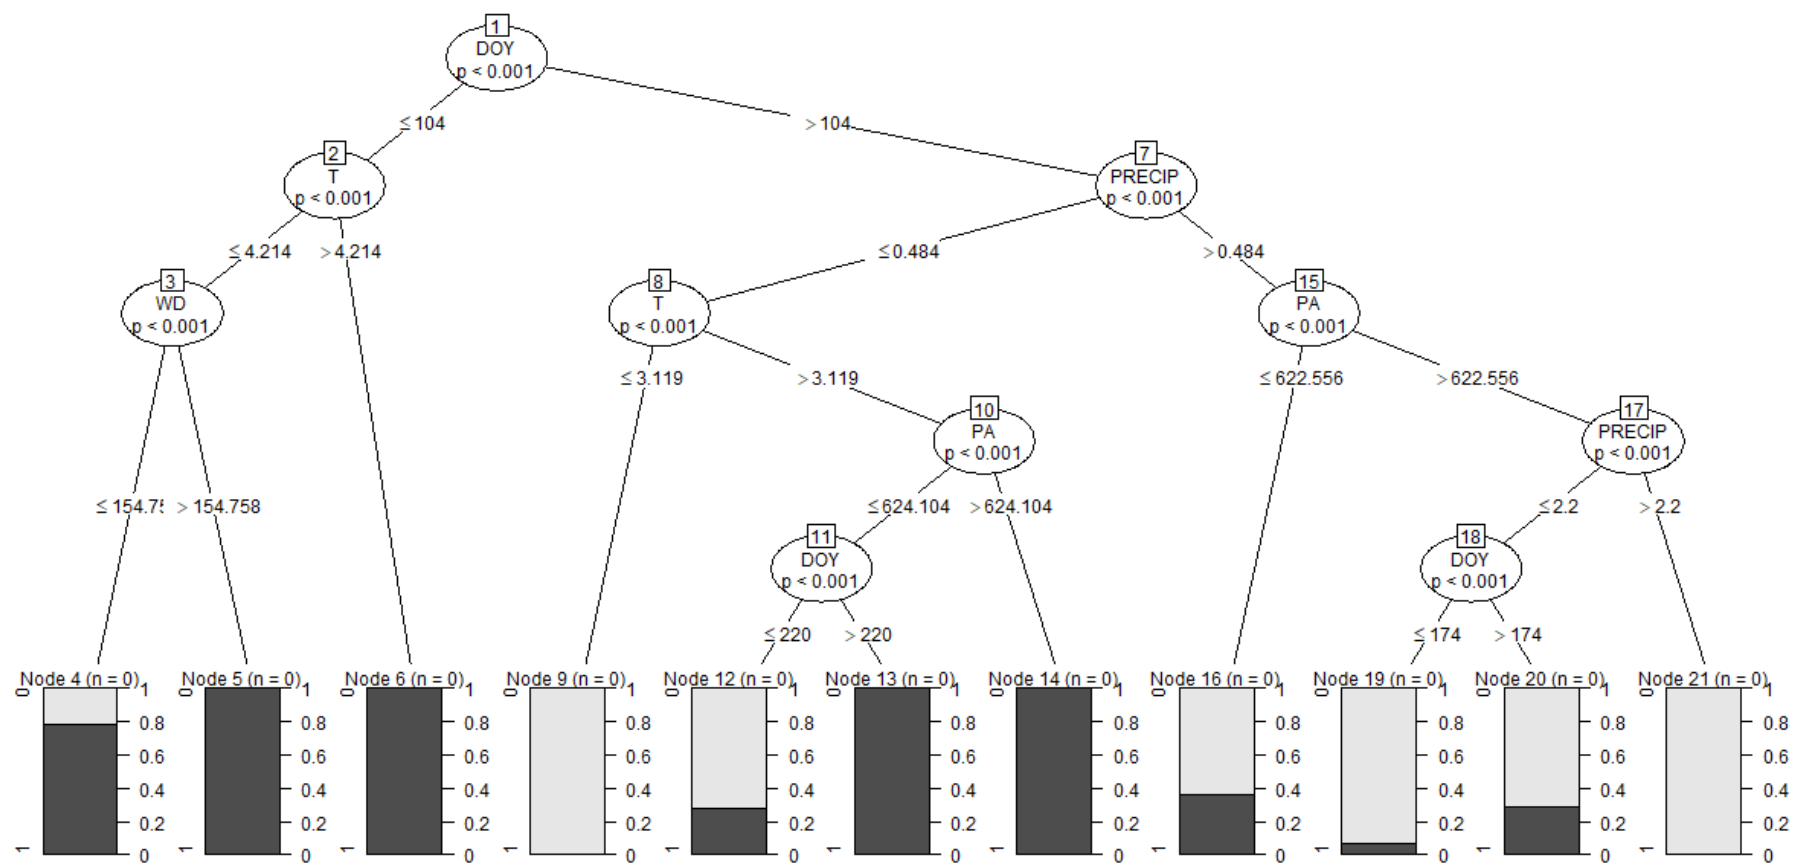


**Figura 30.** Importancia e impurezas de variables en clasificación espacial.

Elaborado por: Paul David Carchipulla Morales

## 6.4.SCRIPTS Y ÁRBOL DE DECISIÓN DE CLASIFICACIÓN TEMPORAL

Los códigos utilizados para programar la clasificación temporal en el software estadístico R se encuentran en los Anexos 2 y 3. Esta clasificación mediante árboles de decisión trabajó con 1000 árboles similares al de la Figura 31. Al ser muestras aleatorias, es posible que la importancia de las variables cambie según el árbol (Breiman, 2001). Aun así, la siguiente figura muestra un ejemplo de los árboles de decisión generados con 21 nodos, el cual sigue la importancia mostrada en la Figura 27. De este modo, este ejemplo de árbol de decisión muestra que la variable día del año facilita la clasificación temporal, seguida por la precipitación y temperatura.



**Figura 31.** Árbol de decisión en clasificación temporal.

Elaborado por: Paul David Carchipulla Morales

## **6.5.SCRIPTS Y ÁRBOL DE DECISIÓN DE CLASIFICACIÓN ESPACIAL**


Los códigos utilizados para programar la clasificación espacial en el software estadístico R se encuentran en los Anexos 4, 5, 6 y 7. Esta clasificación supervisada utilizó 100 árboles de decisión, que trabajaron con aproximadamente 1667 nodos. En este sentido, no se pudo mostrar un ejemplo de árbol de decisión de la clasificación espacial porque la extensión del mismo impide una visualización óptima. Aunque durante una exploración del mismo, se observó un comportamiento similar a la importancia esperada en las variables. Donde la pendiente fue la variable más importante, seguida por las variables VH\_S, DOY, DEM, y VV\_S. En el caso de requerirse observar el árbol de decisión, se puede hacerlo según el script del Anexo 4.

## **6.6.CLASIFICACIÓN ESPACIO-TEMPORAL DEL HUMEDAL**

El resultado de combinar la clasificación espacial con la temporal fue una serie de 194 imágenes entre los años 2017 y 2019. Estas imágenes muestran hectáreas de suelo seco, húmedo y cerca de la saturación, así como valores de NDVI y NDWI. Para visualizar las imágenes se puede acceder al siguiente link: <https://PIJ-17-05.users.earthengine.app/view/sar-landtrendr>. La variación temporal de la superficie de suelo seco, húmedo y cerca de la saturación también se puede observar en la Figura 32, Figura 33, y Figura 34, que son las series de tiempo que permiten seleccionar las imágenes clasificadas en línea. Las series de tiempo de la clasificación del suelo muestran variaciones marcadas en las estaciones de suelo seco, y variaciones menos evidentes en las estaciones de suelo húmedo, y cerca de la saturación. Además, la presencia de vertederos disminuyó la descarga del humedal, lo que redujo la extensión de suelo seco en los primeros meses de los años 2018 y 2019.

Los periodos con mayor extensión de suelo seco están marcados de color gris e indican que a inicios de cada año hay mayor cobertura de suelo seco, así como un cambio paulatino anual en la cantidad de hectáreas (Figura 32). También es necesario destacar que aproximadamente 8.4 hectáreas del área de estudio son

cubiertas por las vías de acceso y serán permanentemente consideradas como suelo seco. Por tanto, la información de la Figura 32 indica que el año 2017 tuvo un descenso drástico en la superficie de suelo seco. En este sentido, las extensiones de suelo seco mayores a 175 ha registradas en 2017 se redujeron a 170 ha en el año 2018, junto con un registro atípico en febrero de 2018. Este aumento atípico de suelo seco del 8 de febrero de 2018 no fue posible compararlo con los registros meteorológicos debido al vacío de datos climáticos en dicha fecha. Por otra parte, el año 2019 destaca por la estacionalidad marcada en los primeros meses, en la cual se observa un crecimiento de superficie seca que da paso al inicio del año 2020.

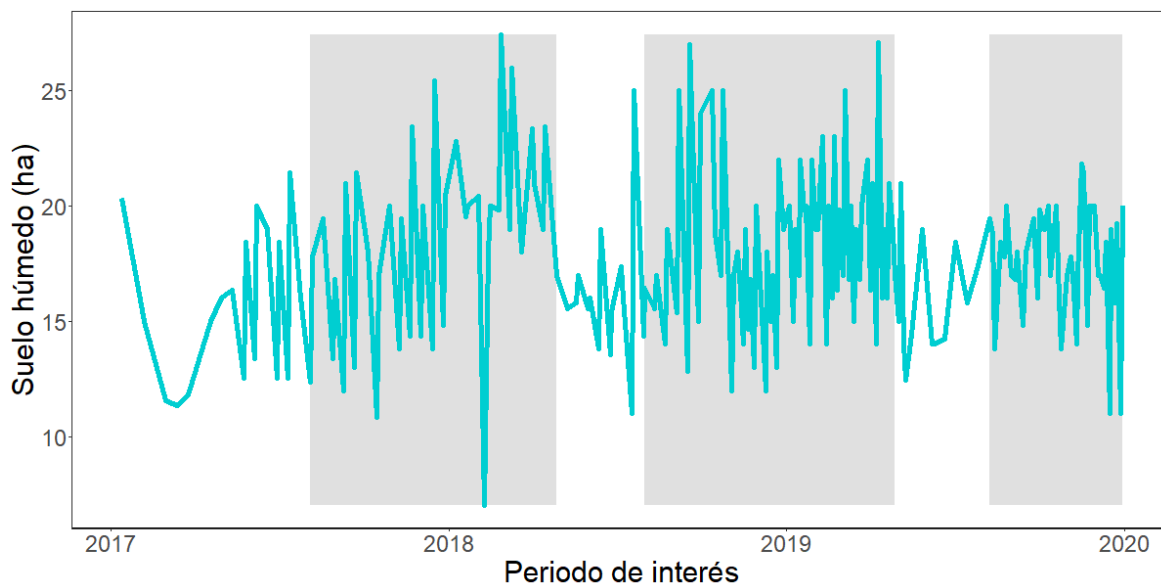


**Figura 32.** Evolución de la clasificación espacio-temporal del suelo seco.

Elaborado por: Paul David Carchipulla Morales

Al mismo tiempo, la instalación de vertederos en el año 2017 parece no haber afectado significativamente a la superficie de suelo húmedo, ya que se mantiene el comportamiento estacional durante todo el periodo de estudio (Figura 33). De esta manera, un periodo húmedo marcado de color gris con extensiones alrededor de las 20 ha se observa desde agosto hasta abril. La baja variabilidad de la estacionalidad de suelo húmedo se asocia a que esta clase limita la superficie del humedal Pugllahoma. Por esta razón, el suelo húmedo mantiene una extensión alrededor de las 20 ha y un registro atípico de 8 ha, correspondiente a la misma

fecha de febrero de 2018 cuando se registró un aumento atípico de la superficie de suelo seco. Además, las ocasiones en las que se presenta una disminución de suelo húmedo se asocian al aumento de suelo cerca de la saturación. Al contrario, los leves aumentos en la extensión de suelo húmedo se atribuye al descenso de superficie de suelo seco (Figura 32 y Figura 34).




**Figura 33.** Evolución de la clasificación espacio-temporal del suelo húmedo.

Elaborado por: Paul David Carchipulla Morales

En el caso de la Figura 34, los dos aumentos en la extensión de suelo cerca de la saturación se logran distinguir con mayor claridad a lo largo del periodo de estudio. Como se puede ver en la Figura 34, los colores gris y gris oscuro representan la primera y segunda crecida. En este sentido, el primer aumento mantiene una alta frecuencia de extensiones cerca de las 15 ha, mientras la segunda crecida muestra una tendencia a registrar extensiones de 10 ha. Así mismo, al relacionar el suelo cerca de la saturación con los otros niveles de saturación se marca un periodo de sequía en el suelo en los meses de enero, febrero y marzo. En cambio, el periodo de mayor saturación de agua en el suelo se encuentra en los meses de junio a septiembre y de noviembre a diciembre.






**Figura 34.** Evolución de la clasificación espacio-temporal del suelo cerca de la saturación.

Elaborado por: Paul David Carchipulla Morales

## 6.7. EVALUACIÓN DEL MODELO TEMPORAL

De acuerdo a RF, a cada fecha se le otorga una clase si esta obtuvo una probabilidad mayor al 50% de acierto (Sullivan, 2017). Este criterio puede no ser el óptimo para cada caso, por lo que se sugiere comprobar los resultados con las muestras de clases conocidas, obtenidas por mediciones de campo (Ramasubramanian y Singh, 2019). En este caso se prefiere elegir las fechas que concuerden con la clasificación climática estacional del área de interés (Shepherd y Water, 2009). Por lo cual, al graficar la probabilidad de clasificación frente a la fecha como se hizo en la Figura 35, se prefirió seleccionar las fechas con una probabilidad mayor al 60% (Hird et al., 2017). Las fechas del periodo de saturación se encuentran representadas de color azul y limitadas por las dos flechas que se encuentran en la parte alta de la gráfica. Por otra parte, las fechas del periodo de aparente estiaje se representan de color naranja y limitadas por las tres flechas sobre el umbral de error de clasificación. De este modo, las 237 fechas clasificadas inicialmente dentro del periodo de saturación pasaron a ser 200 fechas y las 524 fechas clasificadas dentro del periodo de estiaje pasaron a ser 488.




**Figura 35.** Evaluación de la probabilidad en clasificación temporal.

Fuente: FONAG, 2019

Elaborado por: Paul David Carchipulla Morales

## 6.8. EVALUACIÓN DEL MODELO ESPACIAL

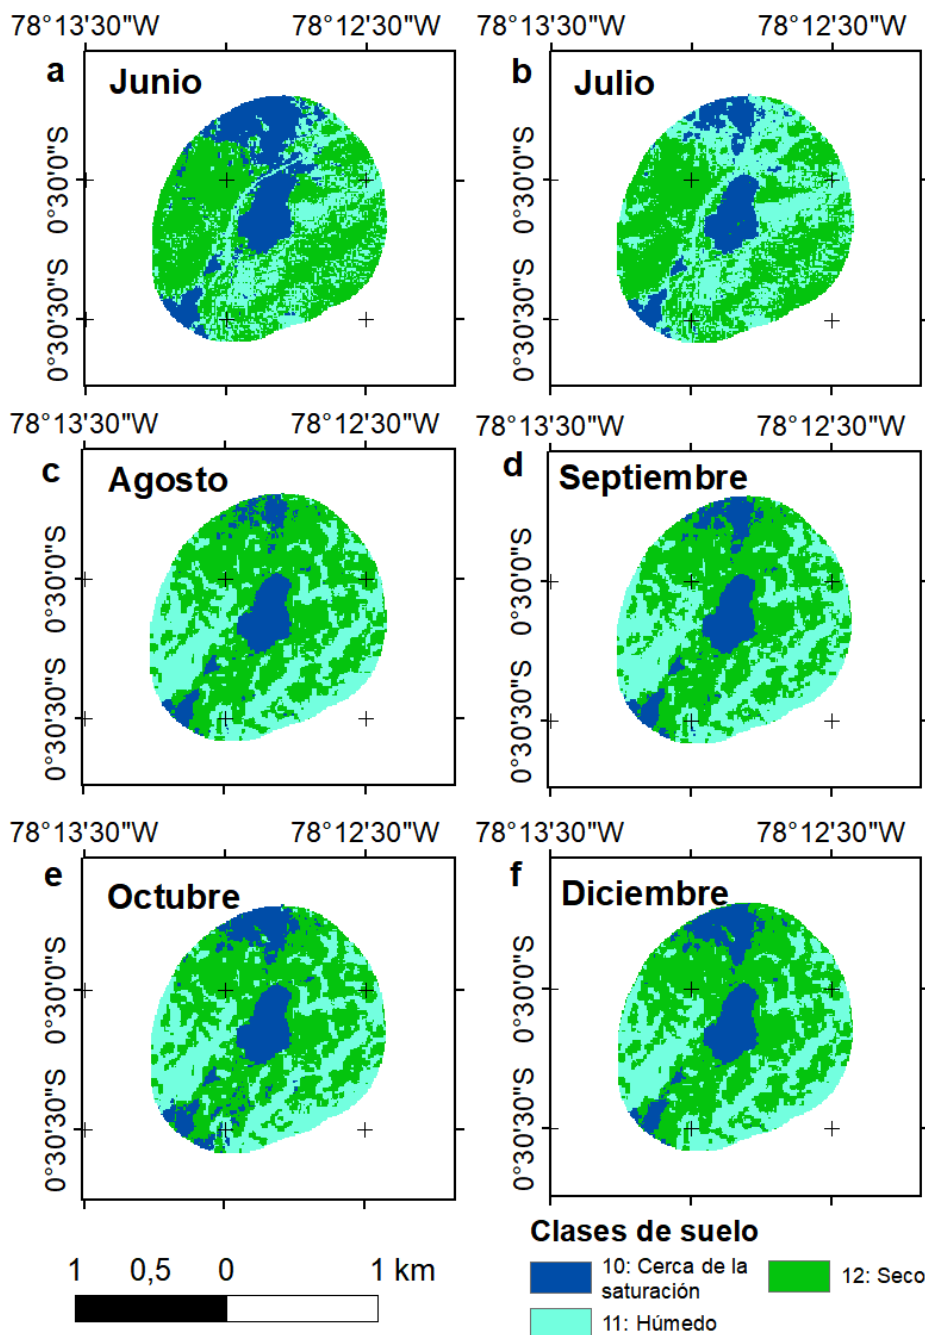
La clasificación no supervisada que utilizó las variables no colineales de la Tabla 15, junto con valores de pendiente, y día del año de captura de imagen (Figura 36). La correlación entre los índices espectrales es superior a 0.7, y tiene sentido al considerar que estos índices buscan la respuesta espectral de la vegetación con mayor clorofila y agua. En otras palabras, los índices espectrales miden la respuesta espectral de la clorofila o del agua para clasificar las áreas con mayor cobertura vegetal húmeda. Lo que significa que varios de estos índices tuvieron el mismo objetivo durante la clasificación y explica su correlación. Por tal motivo, se decidió que solo sería necesario utilizar un índice que evalúe la vegetación y un índice que evalúe el nivel de saturación del suelo en el área de interés. De este modo, las variables MNDWI, NDVI, DEM, y DOY fueron seleccionadas para la clasificación no supervisada.



**Figura 36.** Correlación de índices espectrales en el humedal.

Elaborado por: Paul David Carchipulla Morales


Se puede visualizar la comparación de resultados entre ambas clasificaciones en fechas similares a través del siguiente link: <https://PIJ-17-05.users.earthengine.app/view/landtrendrassessment>. También se muestran los resultados de la clasificación no supervisada en la Figura 37 y la Figura 38. En el año 2017, la mayor saturación se visualiza sobre el humedal Pugllohuma y un aumento de suelo cerca de la saturación al norte del humedal. La superficie cerca de la saturación varía entre 20 y 50 ha, el suelo húmedo entre 50 y 75 ha, mientras el suelo seco varía entre 95 y 125 ha. Los meses de junio y julio muestran albergar mayores extensiones de suelo cerca de la saturación. Por otro lado, agosto y septiembre son los meses de menor saturación de agua en el suelo.



**Figura 37.** Clasificación no supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2017.

Elaborado por: Paul David Carchipulla Morales

En la Figura 38, el periodo de mayor saturación se desplaza a los meses de agosto y octubre de 2018. Así mismo, el periodo de menor saturación de agua en el suelo se desplaza a diciembre de 2018 y febrero de 2019. En este sentido, la extensión de suelo seco se encontró entre 110 y 125 ha, el suelo húmedo entre 50 y 65 ha, y el suelo cerca de la saturación entre 15 y 30 ha.



**Figura 38.** Clasificación no supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el año 2018 y primer trimestre del año 2019.

Elaborado por: Paul David Carchipulla Morales

La Figura 37 y la Figura 38 muestran una distribución de agua basada en el contenido de agua dentro de la vegetación del área de interés y las extensiones de vegetación. La clasificación no supervisada establece que la mayor saturación de

agua debería encontrarse en el centro del área de interés. Además, la presencia de vegetación favorece mayormente a la clasificación no supervisada, pues sin ella la clasificación no supervisada mostraba resultados dispersos. Es evidente que la clasificación supervisada es diferente en varios aspectos a la clasificación no supervisada. Aunque ambas logran delimitar el humedal Pugllohuma, la clase de suelo que identifica al humedal es diferente en cada clasificación. La cuantificación de las áreas clasificadas para ambas misiones satelitales se muestra a continuación en la Tabla 16 y Tabla 17.

**Tabla 16.**  
*Muestra de S1 para validación.*

Fecha (dd/mm/yy)	Suelo cerca de la saturación (Ha)	Suelo húmedo (Ha)	Suelo Seco (Ha)
05/06/2017	12.6	164.0	18
13/07/2017	20.4	168.6	5.5
18/08/2017	19.4	169.6	5.5
21/09/2017	13	164.9	16.7
17/12/2017	18	171.1	5.5
16/12/2017	23.4	168.2	3
09/01/2018	23	169.6	2
25/08/2018	21	170.1	3.5
24/10/2018	23	168.6	3
23/12/2018	22	169.6	3
15/02/2019	21	172.6	1

Elaborado por: Paul David *Carchipulla* Morales

**Tabla 17.**  
*Muestra de S2 para validación.*

Fecha (dd/mm/yy)	Suelo cerca de la saturación (Ha)	Suelo húmedo (Ha)	Suelo Seco (Ha)
06/06/2017	71.725	100.875	21.808
16/07/2017	95.925	73.784	24.698
20/08/2017	18.729	73.376	102.302
19/09/2017	107.878	67.486	19.043

19/10/2017	91.867	89.686	12.855
18/12/2017	103.929	77.624	12.855
07/01/2018	100.196	78.388	15.824
25/08/2018	100.522	71.188	22.698
24/10/2018	112.753	67.8	13.855
23/12/2018	148.522	25.749	20.137
16/02/2019	120.745	59.918	13.745

Elaborado por: Paul David Carchipulla Morales


La clasificación no supervisada categoriza como área cerca de la saturación al humedal Pugllohuma y calcula que su extensión varía entre 12.5 y 23.5 ha. Por el contrario, la clasificación supervisada categoriza al humedal Pugllohuma como suelo húmedo y suelo cerca de la saturación, con una extensión que varía entre las 92 y 181.5 ha. Estos resultados indican que la clasificación supervisada utilizando imágenes de radar no es efectiva al evaluar la distribución espacial de clases en superficies menores a 20 ha. Por otro lado, ambas clasificaciones muestran ser eficaces al georreferenciar el humedal en el centro del área de monitoreo.

## 6.9.DISCUSIÓN

La clasificación supervisada y la clasificación no supervisada coinciden en mostrar que el humedal Pugllohuma se encuentra en el centro del área de estudio. Sin embargo, ambas clasificaciones difieren en el grado de saturación de agua en el suelo del área de interés. La diferencia de resultados se debe a la respuesta visual que se midió con la clasificación no supervisada y la respuesta morfológica que se midió con la clasificación supervisada (Hribljan et al., 2017). La respuesta espectral indica que las áreas con mayor saturación de agua en el suelo promueven el crecimiento de flora. Por otro lado, la respuesta a la retrodispersión establece que el cambio morfológico del terreno se debe a la absorción de agua en las especies de flora de *Werneria nubigena*, comúnmente conocidas como almohadillas. Las almohadillas del terreno aumentan su volumen por la retención de agua y como resultado existe un cambio en la morfología del terreno.

Una muestra de la clasificación supervisada se encuentra en la Figura 39 y la Figura 40. Las clasificaciones mostradas en las siguientes figuras indican la estacionalidad

de la clasificación supervisada en los años 2017 y 2018. La mayor parte de la superficie del humedal Pugllohuma es clasificada como terreno de suelo húmedo o clase 11. También es posible observar al suroeste del humedal Pugllohuma una fracción de terreno que es clasificada como suelo cerca de la saturación con agua o clase 10. El suelo cerca de la saturación varía su extensión desde el centro del humedal hasta el sur del área de influencia. El resto de superficie del área de interés es clasificado como suelo seco o clase 12.




**Figura 39.** Clasificación supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2017.

Elaborado por: Paul David Carchipulla Morales

La Figura 39 y la Figura 40 muestran que el humedal Pugllohuma presenta constante presencia de agua en el suelo. El suelo húmedo cubriría aproximadamente 20 ha la mayor parte del tiempo en el área de interés. Sin embargo, la infiltración de agua que aumenta el volumen de las almohadillas es un evento esporádico que estaría estrechamente relacionado a los eventos de precipitación. Es de este modo que en junio y septiembre del año 2017 habría una



extensión de suelo cerca de la saturación que abarcaría alrededor de 15 ha. Mientras que el resto de meses mostrados en las siguientes figuras mantendrían una superficie de suelo cerca de la saturación menor a 5 ha.



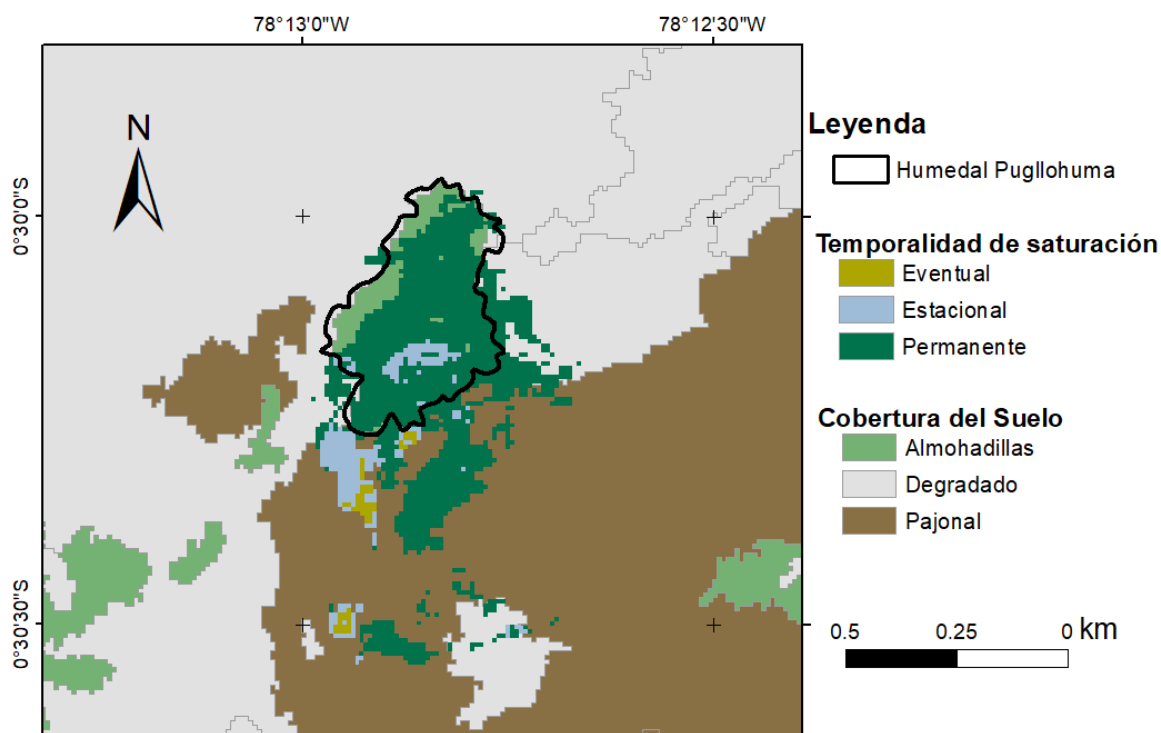
**Figura 40.** Clasificación supervisada de suelo cerca de la saturación (clase 10), húmedo (clase 11), y seco (clase 12) en el segundo semestre del año 2018.

Elaborado por: Paul David Carchipulla Morales

Los resultados de la clasificación espacio-temporal del humedal Pugllohuma han demostrado ser aceptables y permitieron definir las áreas que han sufrido cambios durante el periodo de estudio (Figura 41). La siguiente figura se obtuvo de la media de la clasificación en el periodo de estudio, y observándose la permanencia de las clases que expresan saturación. La clasificación supervisada demostró que el periodo del año influye notablemente en la cobertura del área de interés, esencialmente en la presencia de suelo cerca de la saturación (Gabrielsen et al., 2016). Así mismo, el modelo de clasificación temporal ha confirmado que los ecosistemas cercanos al Antisana tienen una fuerte influencia por la temperatura,

mientras la elevación del terreno influye importantemente en la clasificación espacial (Manciati et al., 2014; y Rüetschi et al., 2018)

En la Figura 41 se muestra las áreas que son más probables a sufrir cambios en la clasificación durante el periodo de interés. En este sentido, el centro del humedal y la zona sur del mismo son las superficies donde ocurren cambios estacionales y eventuales. Por otra parte, la superficie cubierta por almohadillas presenta una acumulación permanente de agua. Esto significa que el área con permanente presencia de agua se encuentra en lo que ya se es conocido como humedal Pugllohuma con un aumento del nivel saturación al sur del humedal, tal y como se vio en diferentes imágenes de la clasificación supervisada y no supervisada.



**Figura 41.** Temporalidad promedio de saturación en el humedal Pugllohuma.

Elaborado por: Paul David Carchipulla Morales

Aun así, en dicha imagen ha sido imposible identificar los espejos de agua identificados durante las visitas al área de interés, Anexo 8. Esto demuestra la limitación de estudiar terrenos con superficies menores a 100 ha. Sin embargo, es posible observar la dinámica de los límites del humedal Pugllohuma, por el efecto

que tiene el agua al saturar el suelo y aumentar el volumen de las almohadillas del terreno (Fernandez et al., 2015; White et al., 2015).

Por otro lado, las figuras de la sección 6.6 Clasificación espacio-temporal del humedal señalan la constante presencia de humedad en el suelo. Las zonas del humedal que fueron clasificadas como suelo húmedo coinciden con los límites del humedal Pugllohuma definidos en estudios anteriores (FONAG, 2019). Esto denota las virtudes temporales del estudio, así como las falencias espaciales en un área tan pequeña. Esto también se puede observar en la Tabla 16 y Tabla 17, donde la superficie de cada clase aumenta en las mismas fechas para S1 y S2 a diferentes escalas. En este sentido, se presume que la cantidad de hectáreas de suelo seco podría estar sobrestimándose en S2 o subestimándose en S1. Mientras el primero midió una respuesta espectral en base a clorofila o agua, el segundo ha medido una respuesta en base a la forma de los objetos del terreno estudiado (Fernandez et al., 2015; White et al., 2015).

## **CAPÍTULO 7. CONCLUSIONES Y RECOMENDACIONES**

### **7.1. CONCLUSIONES**

- En este trabajo se identificó la relación entre los cambios espacio-temporales del humedal Pugllohuma, mediciones topográficas y climáticas. Lo más destacado fue la importancia identificada para cada variable utilizada en los modelos de clasificación supervisada, porque de esta forma se pudo comprobar que el nivel freático en el humedal se rige primordialmente por el día del año, temperatura atmosférica y precipitación en lo que a tiempo respecta, mientras la elevación del terreno afecta en mayor medida a los cambios espaciales. Aun así, estas variables no pueden describir los cambios espacio-temporales del humedal por sí solas, por lo que fue necesario incluir datos de dirección del viento, humedad relativa, y presión atmosférica en el análisis temporal del humedal, así como datos de ángulo y día de captura de imagen, pendiente del terreno y polarimetría del área de estudio en el análisis espacial.
- Con base en las series temporales de los cambios en el suelo del humedal Pugllohuma, se clasificaron las zonas de saturación con agua en las categorías permanente, estacional y eventual. En este sentido, las series de tiempo ubican a los cambios estacionales en el centro y sur del humedal, los cambios eventuales ocurren en el sur del humedal, y la acumulación permanente de agua se encuentra sobre la superficie de almohadillas en el área de estudio. Por tanto, la presencia de almohadillas resulta ser fundamental para la capacidad de retención de agua en el humedal. Además, es importante mencionar que existe una dificultad al interpretar la clasificación mediante árboles de decisión porque los resultados no muestran los comportamientos atípicos y deben ser identificados subjetivamente.
- La clasificación no supervisada utilizando S2 validó los niveles de saturación con agua en el suelo del humedal Pugllohuma. De esta forma, la comparación entre los resultados de ambas metodologías señala que la clasificación supervisada utilizando imágenes de radar no es efectiva al evaluar la distribución espacial de clases en superficies menores a 20 ha

debido a la corrección que requieren las imágenes radar por el speckle. En este sentido, los resultados del modelo espacio-temporal tienen menor incertidumbre cuando la superficie de suelo en el humedal se conforma por las medias de cada clasificación, y las cuales son aproximadamente: 170 ha de suelo seco, 17 ha de suelo húmedo, y 7 ha de suelo cerca de la saturación.

- La clasificación espacio-temporal del nivel de saturación del humedal Pugllahoma señaló un comportamiento estacional en las series de tiempo de los resultados. Entonces resulta que el periodo de sequía en el suelo ocurre en los meses de enero, febrero y marzo, mientras el periodo de mayor saturación de agua en el suelo se encuentra en los meses de junio a septiembre y de noviembre a diciembre. De este modo, la mayor saturación con agua en el suelo del humedal fue asociada a los días con 10 mm/día de precipitación, 94% de humedad relativa, 623 mbar de presión atmosférica, temperaturas de 5 °C, y corrientes de viento provenientes del sur. Al contrario, las variables espaciales muestran comportamientos más dispersos y difíciles de interpretar.
- Al validar los resultados del presente estudio, se observó que los mapas de la clasificación supervisada muestran límites más definidos entre clases que los presentados en la clasificación no supervisada. Esta diferencia entre los resultados de ambas metodologías denota la importancia de utilizar diferentes variables para monitorear un entorno. En otras palabras, la sensibilidad que tienen los sensores ópticos a los cambios en la vegetación y la sensibilidad de los sensores radar a los cambios topográficos por el contenido de agua en el suelo forman un conjunto de datos clave para descripción de un ecosistema altoandino. Sin embargo, el acceso a la información de imágenes ópticas limita la combinación de ambas tecnologías para realizar un análisis más completo del humedal.

## 7.2.RECOMENDACIONES

- Los cambios espacio-temporales del humedal Pugllohuma se rigen primordialmente por el día del año, elevación del terreno, temperatura atmosférica y precipitación. En este sentido, se recomienda establecer la relación de los cambios espacio-temporales del humedal con las variables mencionadas y otras que no se hayan considerado en el presente estudio, por ejemplo, la radiación. Al mismo tiempo, la información temporal que se incluya en los estudios futuros debe ser recolectada hasta 6 km alrededor del humedal como se hizo en este trabajo y la información espacial debe tener una resolución de 30m x 30m o mejor. Por otra parte, los resultados muestran una mejor eficiencia en la delimitación del área húmeda que en su variabilidad, y se recomienda aplicar la presente metodología con sus fuentes de datos en el mapeo de humedales en largas extensiones de estudio.
- La subjetividad en la interpretación de resultados puede ser resuelta con la adición de información de la cobertura vegetal del terreno. El control y monitoreo de flora implica una guía de trabajo con mayor objetividad a la hora de interpretar resultados. Además, la retrodispersión medida por el sensor radar parece estar relacionada con los cambios morfométricos de flora de la especie *Werneria nubigena*. Esta especie tiene una elevada capacidad de retención de agua y se refleja en el aumento de su volumen. Se recomienda realizar controles de cambio de crecimiento y desarrollo de individuos de la especie *Werneria nubigena* para relacionarlos con la retrodispersión medida por el radar.
- La validación de resultados de la clasificación supervisada mediante imágenes SAR sugiere trabajar con modificaciones a los parámetros ya utilizados de esta herramienta y combinarlos con datos de respuestas espectrales medidas por sensores ópticos. Usar variaciones de los parámetros definidos en este estudio podrían mejorar la precisión al detectar cambios espacio-temporales. Uno de los parámetros que actualmente no se pudo evaluar fue la longitud de onda. En el futuro podría ser posible utilizar otras longitudes de onda, ya que como se mencionó en el GEO Week 2019,

imágenes SAR de las misiones ALOS y ALOS-2 con una longitud de onda L serán liberadas pronto.

- Los humedales de tundra tienen una alta capacidad de retención de gases de efecto invernadero. Esta característica puede utilizarse en las imágenes SAR junto a las imágenes troposféricas de Sentinel-5 para futuros estudios de presencia de humedales. Las áreas con humedales permanentes usualmente tienen menores concentraciones de gases de efecto invernadero que las áreas con humedales estacionales o eventuales.
- La falta de imágenes ópticas para combinarlas con la información radar puede ser resuelta con el uso de diferentes misiones satelitales que trabajen con bandas ópticas similares. El uso de imágenes de varias misiones de satélites ópticos ha mostrado ser efectivo cuando se definen las características que son necesarias de las imágenes para el estudio. Por tal motivo, se debería ampliar el periodo de estudio, ya que misiones como Sentinel-3 llevan trabajando desde el año 2016 y su trayectoria ha concordado en algunas ocasiones con la del área de interés de este trabajo.

## REFERENCIAS

- 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(January), 168–181. <https://doi.org/10.1016/j.rsase.2017.08.010>
- Álvarez, M. G. (2019). *Ecological Modelling of River-Wetland Systems A Case Study for the Abras de Mantequilla Wetland in Ecuador*. CRC Press.
- Amani, M., Mahdavi, S., Afshar, M., Brisco, B., Huang, W., Mirzadeh, S. M. J., White, L., Banks, S., Montgomery, J., & Hopkinson, C. (2019). Canadian wetland inventory using Google Earth Engine: The first map and preliminary results. *Remote Sensing*, 11(7), 1–20. <https://doi.org/10.3390/RS11070842>
- Baghdadi, N., Bernier, M., Gauthier, R., & Neeson, I. (2001). Evaluation of C-band SAR data for wetlands mapping. *International Journal of Remote Sensing*, 22(1), 71–88. <https://doi.org/10.1080/014311601750038857>
- Behnamian, A., Banks, S., White, L., Brisco, B., Milard, K., Pasher, J., Chen, Z., Duffe, J., Bourgeau-Chavez, L., & Battaglia, M. (2017). Semi-automated surfacewater detection with synthetic aperture radar data: A wetland case study. *Remote Sensing*, 9(12), 1–21. <https://doi.org/10.3390/rs9121209>
- Berry, M., Mohamed, A., & Yap, B. W. (2019). Supervised and Unsupervised Learning for Data Science. En *Unsupervised and Semi-Supervised Learning*. <https://doi.org/10.1007/978-3-030-22475-2>
- Bourgeau-Chavez, L., Endres, S., Battaglia, M., Miller, M. E., Banda, E., Laubach, Z., Higman, P., Chow-Fraser, P., & Marcaccio, J. (2015). Development of a bi-national Great Lakes coastal wetland and land use map using three-season PALSAR and Landsat imagery. *Remote Sensing*, 7(7), 8655–8682. <https://doi.org/10.3390/rs70708655>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Cutler, A., Liaw, A., & Wiener, M. (2018). Package ‘randomForest’. *R Cran*, 4.6(14), 6–18. <https://doi.org/10.1023/A:1010933404324>
- Catry, T., Li, Z., Roux, E., Herbreteau, V., Gurgel, H., Mangeas, M., Seyler, F., &



- Dessay, N. (2018). Wetlands and malaria in the amazon: Guidelines for the use of synthetic aperture radar remote-sensing. *International Journal of Environmental Research and Public Health*, 15(3). <https://doi.org/10.3390/ijerph15030468>
- Chen, B., Xiao, X., Li, X., Pan, L., Doughty, R., Ma, J., Dong, J., Qin, Y., Zhao, B., Wu, Z., Sun, R., Lan, G., Xie, G., Clinton, N., & Giri, C. (2017). A mangrove forest map of China in 2015: Analysis of time series Landsat 7/8 and Sentinel-1A imagery in Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 104–120. <https://doi.org/10.1016/j.isprsjprs.2017.07.011>
- Comité Permanente. (2019). *Actualización sobre las iniciativas regionales de Ramsar para 2019*. 1–16.
- Constitución de la República del Ecuador. Registro Oficial 449, 20 de octubre de 2008.
- Corbane, C., Panagiotis, P., & Maffenini, L. (2019). *MASADA Sentinel 1 & 2 User Guide* (Número June). <https://doi.org/10.2760/62083>
- de Groot, R. S., Alkemade, R., Braat, L., Hein, L., & Willemen, L. (2010). Challenges in integrating the concept of ecosystem services and values in landscape planning, management and decision making. *Ecological Complexity*, 7(3), 260–272. <https://doi.org/10.1016/j.ecocom.2009.10.006>
- DeLancey, E. R., Kariyeva, J., Cranston, J., & Brisco, B. (2018). Monitoring Hydro Temporal Variability in Alberta, Canada with Multi-Temporal Sentinel-1 SAR Data. *Canadian Journal of Remote Sensing*, 44(1), 1–10. <https://doi.org/10.1080/07038992.2018.1417734>
- Devore, J. (2018). *Fundamentos de Probabilidad y Estadística* (A. Vega (ed.); Primera). CENGAGE. [https://books.google.com.mx/books?id=cbdromy2XrwC&printsec=frontcover&dq=concepto+de+estadistica+y+probabilidad&hl=es&sa=X&ved=0ahUKEwjU1NDZ9e\\_RAhVKi1QKHSkaAhYQ6AEIjAC#v=onepage&q&f=false](https://books.google.com.mx/books?id=cbdromy2XrwC&printsec=frontcover&dq=concepto+de+estadistica+y+probabilidad&hl=es&sa=X&ved=0ahUKEwjU1NDZ9e_RAhVKi1QKHSkaAhYQ6AEIjAC#v=onepage&q&f=false)
- ECAP. (2018). *Informe de gestión 2018 de la ECAP*.
- El Hajj, M., Baghdadi, N., Bazzi, H., & Zribi, M. (2019). Penetration analysis of SAR signals in the C and L bands for wheat, maize, and grasslands. *Remote Sensing*, 11(1), 22–24. <https://doi.org/10.3390/rs11010031>

- Elsevier B.V. (2020). *Wetland documents by subject area*. Scopus. <https://www.scopus.com/term/analyzer.uri?sid=1f62694a588062ea4be55d7897544be8&origin=resultslist&src=s&s=TITLE-ABS-KEY%28%28%28%28wetland%29+AND+%28detection+or+monitoring%29+AND+%28accuracy%29+AND+%28mapping%29+AND+%28radar%29%29%29%29&sort=cp-f&sdt=b&so>
- EPMAPS, & FONAG. (2018). *Actualización Del Plan De Manejo Del Área de Conservación Hídrica Antisana*.
- ESA. (2015). *Sentinel-2 User Handbook*. European Commission.
- ESA, & Fletcher, K. (2012). *Sentinel-1: ESA's Radar Observatory Mission for GMES Operational Services* (Número ESA SP-1322/1).
- Espinel, G. (2019). *DESARROLLO DE UNA METODOLOGÍA PARA LA EVALUACIÓN DE SATURACIÓN DEL HUMEDAL PUGLLOHUMA MEDIANTE EL USO DE UAVS*. Escuela Politécnica Nacional.
- Fernandez, Y., Escalona, M., & Valdez, J. (2015). Imágenes SAR y Conceptos Básicos de Polarimetría. En *Avances y perspectivas de geomática con aplicaciones ambientales, agrícolas y urbanas* (Primera, Número December 2015). Universidad Autónoma Chapingo.
- Finlayson, M., Everard, M., Irvine, K., McInnes, R. J., Middleton, B. A., van Dam, A. A., & Davidson, N. C. (2018). The Wetland Book I: Structure and Function, Management, and Methods. En *The Wetland Book I: Structure and Function, Management, and Methods*. Springer. <https://doi.org/10.1007/978-90-481-9659-3>
- Finlayson, M., Milton, R., Prentice, C., & Davidson, N. (2018). *The Wetland Book II: Distribution, Description, and Conservation*. Springer. <https://doi.org/https://doi.org/10.1007/978-94-007-4001-3>
- FONAG. (2016). *Diseño de monitoreo del humedal Pugllohuma FONAG*. [http://infoagua-guayllabamba.ec/repositorio/web/files/Diseño del monitoreo de humedal.pdf](http://infoagua-guayllabamba.ec/repositorio/web/files/Diseño%20del%20monitoreo%20de%20humedal.pdf)
- FONAG. (2017). Informe de cumplimiento de metas: FONAG 2017. En *Universitas Nusantara PGRI Kediri*. <http://www.albayan.ae>
- FONAG. (2018). *Términos de referencia - 0024: CONTRATAR LA IMPLEMENTACIÓN DEL PROCESO DE RESTAURACION ACTIVA II FASE*

- DEL HUMEDAL PUGLLOHUMA DE LA RESERVA ECOLÓGICA ANTISANA*". FONAG. (2019). *Informe De Cumplimiento De Metas - Plan De Monitoreo 2019*.
- Gabrielsen, C. G., Murphy, M. A., & Evans, J. S. (2016). Using a multiscale, probabilistic approach to identify spatial-temporal wetland gradients. *Remote Sensing of Environment*, *184*, 522–538. <https://doi.org/10.1016/j.rse.2016.07.034>
- Ghosh, A., Sharma, R., & Joshi, P. K. (2014). Random forest classification of urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion. *Applied Geography*, *48*, 31–41. <https://doi.org/10.1016/j.apgeog.2014.01.003>
- Gorelick, N. (2016). *Classifiers and Classification*. <https://goo.gl/rxOJFe%0A>
- Gulácsi, A., & Kovács, F. (2020). Sentinel-1-imagery-based high-resolution water cover detection on wetlands, aided by google earth engine. *Remote Sensing*, *12*(10), 1–20. <https://doi.org/10.3390/rs12101614>
- Guo, M., Li, J., Sheng, C., Xu, J., & Wu, L. (2017). A review of wetland remote sensing. *Sensors (Switzerland)*, *17*(4), 1–36. <https://doi.org/10.3390/s17040777>
- Han, H., Guo, X., & Yu, H. (2016). Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*, *0*, 219–224. <https://doi.org/10.1109/ICSESS.2016.7883053>
- Hariharan, S., Mandal, D., Tirodkar, S., Kumar, V., Bhattacharya, A., & Lopez-Sanchez, J. M. (2018). A Novel Phenology Based Feature Subset Selection Technique Using Random Forest for Multitemporal PolSAR Crop Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *11*(11), 4244–4258. <https://doi.org/10.1109/JSTARS.2018.2866407>
- Henderson, F. M., & Lewis, A. J. (2008). Radar detection of wetland ecosystems: A review. *International Journal of Remote Sensing*, *29*(20), 5809–5835. <https://doi.org/10.1080/01431160801958405>
- Hird, J. N., DeLancey, E. R., McDermid, G. J., & Kariyeva, J. (2017). Google earth engine, open-access satellite data, and machine learning in support of large-area probabilistic wetland mapping. *Remote Sensing*, *9*(12).

- <https://doi.org/10.3390/rs9121315>
- 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>
- Huang, W., DeVries, B., Huang, C., Lang, M. W., Jones, J. W., Creed, I. F., & Carroll, M. L. (2018). Automated extraction of surface water extent from Sentinel-1 data. *Remote Sensing*, 10(5), 1–18. <https://doi.org/10.3390/rs10050797>
- Hunt, B. B., Smith, B. A., Ph, D., Campbell, S., & Liang, S. (2004). *Groundwater-Level Monitoring Program: Example from the Barton Springs Segment of the Edwards Aquifer, Central Texas. January 2004*, 1–10.
- INABIO. (2020). *Turberas altoandinas: avances en las investigación*. <http://inabio.biodiversidad.gob.ec/events/conferencia-turberas-altoandinas-avances-en-las-investigacion/>
- INAMHI. (2012). Anuario Meteorológico 2012 № 52. En *Servicio meteorológico* (Número 52). [http://www.serviciometeorologico.gob.ec/wp-content/uploads/anuarios/meteorologicos/Am 2012.pdf](http://www.serviciometeorologico.gob.ec/wp-content/uploads/anuarios/meteorologicos/Am%202012.pdf)
- INAMHI. (2020). *Emisión de información estadística meteorológica e hidrológica para el sector público y académico* (Número 00).
- 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>
- Kennedy, R. E., Yang, Z., Gorelick, N., Braaten, J., Cavalcante, L., Cohen, W. B., & Healey, S. (2018). Implementation of the LandTrendr algorithm on Google Earth Engine. *Remote Sensing*, 10(5), 1–10. <https://doi.org/10.3390/rs10050691>
- Lasso, C., Rial, A., Colonnello, Giuseppe Machado-Allison, A., & Trujillo, F. (2014). XI. Humedales de la orinoquia (Colombia - Venezuela). En *Dk* (Número Serie Editorial Recursos Hidrobiológicos y Pesqueros Continentales de Colombia). Instituto de Investigación de Recursos Biológicos Alexander von Humboldt (IAvH). <https://doi.org/10.1017/CBO9781107415324.004>

- Liebig, V. (2005). CEOS Earth Observation Handbook. *ESA*, *www.eohand-book.com*, 212. [http://eohandbook.com/eohb2005/CEOS\\_EOHB\\_2005.pdf](http://eohandbook.com/eohb2005/CEOS_EOHB_2005.pdf)
- Codigo Organico Del Ambiente, Registro Oficial Suplemento 983 \_\_\_\_ (2017). [http://gobiernoabierto.quito.gob.ec/Archivos/Transparencia/2017/07julio/A2/A NEXOS/PROCU\\_CODIGO\\_ORGANICO\\_ADMINISTRATIVO.pdf](http://gobiernoabierto.quito.gob.ec/Archivos/Transparencia/2017/07julio/A2/A NEXOS/PROCU_CODIGO_ORGANICO_ADMINISTRATIVO.pdf)
- MAAE. (2019). *Humedales del Ecuador*. SUIA. <http://suia.ambiente.gob.ec/web/humedales/inicio>
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., & Gill, E. (2019). The first wetland inventory map of newfoundland at a spatial resolution of 10 m using sentinel-1 and sentinel-2 data on the Google Earth Engine cloud computing platform. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010043>
- Makynen, M., & Karvonen, J. (2017). Incidence Angle Dependence of First-Year Sea Ice Backscattering Coefficient in Sentinel-1 SAR Imagery over the Kara Sea. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6170–6181. <https://doi.org/10.1109/TGRS.2017.2721981>
- Maltby, E. (2009). *Functional assessment of wetlands: towards evaluation of ecosystem services*. CRC Press.
- Manciati, C., Villacís, M., Taupin, J. D., Cadier, E., Galárraga-Sánchez, R., & Cáceres, B. (2014). Empirical mass balance modelling of South American tropical glaciers: Case study of Antisana volcano, Ecuador. *Hydrological Sciences Journal*, 59(8), 1519–1535. <https://doi.org/10.1080/02626667.2014.888490>
- Marechal, C., Pottier, E., Hubert-Moy, L., & Rapinel, S. (2012). One year wetland survey investigations from quad-pol RADARSAT-2 time-series SAR images. *Canadian Journal of Remote Sensing*, 38(3), 240–252. <https://doi.org/10.5589/m12-017>
- Mattia, F., Balenzano, A., Satalino, G., Lovergine, F., Loew, A., Peng, J., Wegmuller, U., Santoro, M., Cartus, O., Dabrowska-Zielinska, K., Musial, J., Davidson, M., Yueh, S., Kim, S., Das, N., Colliander, A., Johnson, J., Ouellette, J., Walker, J., ... Jackson, T. (2017). SENTINEL-1 HIGH RESOLUTION SOIL MOISTURE. *IEEE International Geoscience and Remote Sensing Symposium*, 5533–5536.
- MEA. (2005). *Ecosystems and human well-being; Synthesis*. Island Press.

- Mehta, A., & Flores, Á. (2018). *El Monitoreo de la Calidad del Agua Mediante el Procesamiento de Imágenes Satelitales*.
- Miraglia, M., Flores, A., Rivarola y Benitez, M., D'Liberis, M., Galván, L., Natale, D., & Rodríguez, M. (2010). Manual de Cartografía , Teleobservación y Sistemas de Información Geográfica. En *Universidad Nacional de General Sarmiento Manual*. [https://ens9004-mza.infod.edu.ar/sitio/upload/01-\\_MIRAGLIA\\_Y\\_OTROS\\_.PDF%0Ahttps://www.tysmagazine.com/manual-de-cartografia-teleobservacion-y-sistemas-de-informacion-geografica/](https://ens9004-mza.infod.edu.ar/sitio/upload/01-_MIRAGLIA_Y_OTROS_.PDF%0Ahttps://www.tysmagazine.com/manual-de-cartografia-teleobservacion-y-sistemas-de-informacion-geografica/)
- Mleczko, M., & Mróz, M. (2018). Wetland mapping using SAR data from the Sentinel-1A and TanDEM-X missions: A comparative study in the Biebrza Floodplain (Poland). *Remote Sensing*, 10(1), 1–15. <https://doi.org/10.3390/rs10010078>
- Moreira, A. (2013). Synthetic Aperture Radar (SAR): Principles and Applications. *4th Advanced Training course in Land Remote Sensing*. [www.dlr.de/HR](http://www.dlr.de/HR)
- Myers, A. C., Finnegan, P. J., & Breedlove, J. D. (1999). *Analysis of Water-Level Data and Ground-Water Flow Modeling at Fort Riley , Kansas*. July.
- Naghdy, G. A., Todd, C., Olaode, A., & Naghdy, G. (2014). Unsupervised Classification of Images: A Review. *International Journal of Image Processing (IJIP)*, 8, 325. <https://www.researchgate.net/publication/265729668>
- Navarro, J. A. (2017). First experiences with google earth engine. *GISTAM 2017 - Proceedings of the 3rd International Conference on Geographical Information Systems Theory, Applications and Management, Gistam*, 250–255. <https://doi.org/10.5220/0006352702500255>
- North, G., & Kim, K.-Y. (2017). *Energy Balance Climate Models*. Wiley-VCH.
- Páez-Bimos, S. (2018). *Análisis datos meteorológicos: Estación M5126 PRAA - Jatunhuayco*. 1–7.
- Palma, K. (2020). *Evaluación del estado del humedal pugllohuma, perteneciente al Área de Conservación Hídrica Antisana (ACHA), mediante el análisis de índices espectrales de imágenes capturadas desde una aeronave no tripulada (UAV)*. Escuela Politécnica Nacional.
- Pascual, I. (2018). *Clasificación de áreas sembradas y determinación del momento de cosecha en Caña de azúcar y Pastizales mediante imágenes ópticas y SAR*. Universidad Nacional de Córdoba.

- Pekel, J. F., Cottam, A., Gorelick, N., & Belward, A. S. (2016). High-resolution mapping of global surface water and its long-term changes. *Nature*, *540*(7633), 418–422. <https://doi.org/10.1038/nature20584>
- Pena-Regueiro, J., Sebastiá-Frasquet, M. T., Estornell, J., & Aguilar-Maldonado, J. A. (2020). Sentinel-2 application to the surface characterization of small water bodies in Wetlands. *Water (Switzerland)*, *12*(5), 1–16. <https://doi.org/10.3390/w12051487>
- Phiri, D., & Morgenroth, J. (2017). Developments in Landsat land cover classification methods: A review. *Remote Sensing*, *9*(9). <https://doi.org/10.3390/rs9090967>
- Podest, E. (2018a). *SAR para el Mapeo de Inundaciones*. <https://arset.gsfc.nasa.gov/disasters/webinars/intro-SAR>
- Podest, E. (2018b). Conceptos Básicos del Radar de Apertura Sintética. *La Teledetección por Radar y sus Aplicaciones para la Tierra, el Agua y Desastres*, 51. <https://arset.gsfc.nasa.gov/sites/default/files/disasters/SAR-17/Session1-SAR-Spanish.pdf>
- Podest, E., & McCartney, S. (2019). SAR for Flooding Mapping using Google Earth Engine. *NASA Applied Remote Sensing Training Program*.
- Ramasubramanian, K., & Singh, A. (2019). Machine learning using R. En *Machine Learning Using R*. APRESS. <https://doi.org/10.1007/978-1-4842-2334-5>
- Ramkumar, M., Kumaraswamy, K., & Mohanraj, R. (2015). Environmental Management of River Basin Ecosystems. En *Springer Earth System Sciences* (Número January). <https://doi.org/10.1007/978-3-319-13425-3>
- Rebala, G., Rabi, A., & Churiwala, S. (2019). *An Introduction to machine learning*. Springer. [https://doi.org/10.1007/978-1-62703-748-8\\_7](https://doi.org/10.1007/978-1-62703-748-8_7)
- Rojas, D. (2018). *Especies de macroinvertebrados bentónicos existentes en los microhábitats de ríos de páramo, caso de estudio: río Jatunhuayco*. Escuela Politécnica Nacional.
- Rokni, K., Ahmad, A., Selamat, A., & Hazini, S. (2014). Water feature extraction and change detection using multitemporal landsat imagery. *Remote Sensing*, *6*(5), 4173–4189. <https://doi.org/10.3390/rs6054173>
- Ros, F., & Guillaume, R. (2020). *Sampling techniques for supervised and unsupervised tasks* (M. Emre (ed.)). Springer. [https://doi.org/10.1007/978-3-030-29349-9\\_1](https://doi.org/10.1007/978-3-030-29349-9_1)

- Rüetschi, M., Schaepman, M. E., & Small, D. (2018). Using multitemporal Sentinel-1 C-band backscatter to monitor phenology and classify deciduous and coniferous forests in Northern Switzerland. *Remote Sensing*, *10*(1), 1–30. <https://doi.org/10.3390/rs10010055>
- Santoso, A. W., Bayuaji, L., Sze, L. T., Lateh, H., & Zain, J. M. (2016). Comparison of various speckle noise reduction filters on synthetic aperture radar image. *International Journal of Applied Engineering Research*, *11*(15), 8760–8767.
- Schulz, H. E., & Lobosco, R. J. (2011). *NATURAL WATER BODIES Edited by. InTech.*
- Schumacher, J. G., & Klesschulte, M. J. (2010). *Investigation of a Monitoring Well Completed in the St. Francois Aquifer in Oregon County, Missouri, 2005–08 Scientific Investigations Report 2010 – 5041. 22.* <https://doi.org/10.3133/sir20105041>
- Schwert, B., Rounds, E., & Tenneson, K. (2018). *Taller de preprocesamiento.*
- Secretaría de la Convención Ramsar. (2006). Manual de la Convención Ramsar. En *Secretaría de la Convención de Ramsar: Vol. 4a. ed.*
- Shepherd, T., & Water, T. (2009a). *Measuring water levels in wells.*
- Shepherd, T., & Water, T. (2009b). *Measuring water levels in wells. June.*
- Shuman, C. S., & Ambrose, R. F. (2003). A comparison of remote sensing and ground-based methods for monitoring wetland restoration success. *Restoration Ecology*, *11*(3), 325–333. <https://doi.org/10.1046/j.1526-100X.2003.00182.x>
- Sistema Integrado de Comunicación del Municipio. (2015). ¿Cómo Llega El Agua a Quito? *El Quiteño*, 369, 12. [www.institutodelaciudad.com.ec%0Awww.quito.gob.ec](http://www.institutodelaciudad.com.ec%0Awww.quito.gob.ec)
- Steinberg, A. (2012). *Water and nature: Natural forms and bodies of water (Primera).* University Publications.
- Sullivan, W. (2017). Machine Learning For Beginners: Algorithms, Decision Tree & Random Forest Introduction. En *Journal of Chemical Information and Modeling*. <https://doi.org/10.1017/CBO9781107415324.004>
- Tamm, T., Zalite, K., Voormansik, K., & Talgre, L. (2016). Relating Sentinel-1 interferometric coherence to mowing events on grasslands. *Remote Sensing*, *8*(10), 1–19. <https://doi.org/10.3390/rs8100802>
- Taylor, C. J., & Alley, W. M. (2001). Ground-water-level monitoring and the



- importance of long-term water-level data. *US Geological Survey Circular*, 1217, 1–68.
- Toth, C., & Lenzano, M. (2014). Geomatics in Earth Sciences. En *GEOACTA* (Vol. 39). Asociación Argentina de Geofísicos y Geodestas.
- Tsyganskaya, V., Martinis, S., Marzahn, P., & Ludwig, R. (2018). Detection of temporary flooded vegetation using Sentinel-1 time series data. *Remote Sensing*, 10(8). <https://doi.org/10.3390/rs10081286>
- UNESCO. (1971). *Convención relativa a los humedales de importancia internacional especialmente como hábitats de aves acuáticas*.
- USDA. (2018). *Estimating the Effects of Wetland Conservation Practices in Croplands*.
- Vepraskas, M. J., & Craft, C. B. (2016). Wetland Soils: Genesis, Hydrology, Landscapes, and Classification: Second Edition. En *Wetland Soils: Genesis, Hydrology, Landscapes, and Classification: Second Edition*.
- Vreugdenhil, M., Wagner, W., Bauer-Marschallinger, B., Pfeil, I., Teubner, I., Rüdiger, C., & Strauss, P. (2018). Sensitivity of Sentinel-1 backscatter to vegetation dynamics: An Austrian case study. *Remote Sensing*, 10(9), 1–19. <https://doi.org/10.3390/rs10091396>
- Wang, X., Zhang, K., Wu, S., Fan, S., & Cheng, Y. (1955). Journal of geophysical research. *Nature*, 175(4449), 238. <https://doi.org/10.1038/175238c0>
- Wei, T., Simko, V., Levy, M., Xie, Y., Jin, Y., & Zemla, J. (2017). Visualization of a Correlation Matrix. *Statistician*, 56, 316–324. <https://github.com/taiyun/corrplot%0Ahttps://github.com/taiyun/corrplot/issues>
- White, L., Brisco, B., Dabboor, M., Schmitt, A., & Pratt, A. (2015). A collection of SAR methodologies for monitoring wetlands. En *Remote Sensing* (Vol. 7, Número 6). <https://doi.org/10.3390/rs70607615>
- Whyte, A., Ferentinos, K. P., & Petropoulos, G. P. (2018). A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms. *Environmental Modelling and Software*, 104, 40–54. <https://doi.org/10.1016/j.envsoft.2018.01.023>
- Wohlfart, C., Winkler, K., Wendleder, A., & Roth, A. (2018). TerraSAR-X and wetlands: A review. *Remote Sensing*, 10(6), 1–24. <https://doi.org/10.3390/rs10060916>

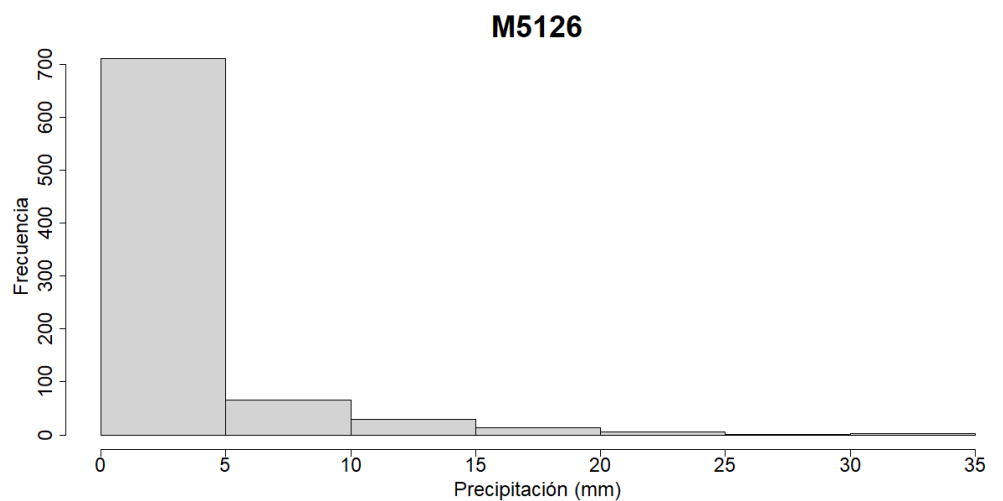
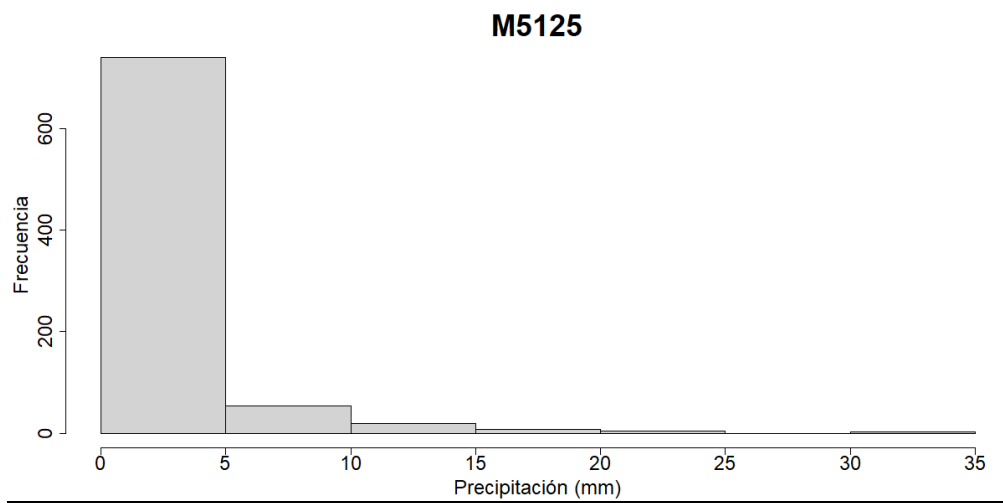
- Wong, B. A., Thomas, C., & Halpin, P. (2019). Automating offshore infrastructure extractions using synthetic aperture radar & Google Earth Engine. *Remote Sensing of Environment*, 233(July), 111412. <https://doi.org/10.1016/j.rse.2019.111412>
- Woodcock, F., & Engel, C. (2005). Operational consensus forecasts. *Weather and Forecasting*, 20(1), 101–111. <https://doi.org/10.1175/WAF-831.1>
- Wright, M. N., Wager, S., & Probst, P. (2020). A Fast Implementation of Random Forests. *CRAN Repository*, 25.
- Wu, J. (2012). *K-means Based Consensus Clustering*. [https://doi.org/10.1007/978-3-642-29807-3\\_7](https://doi.org/10.1007/978-3-642-29807-3_7)
- Yugsi, M. (2018). Caracterización hidrogeológica con determinación de la conductividad hidráulica del humedal “Pugllohuma”. En *Mathematics Education Journal* (Vol. 1, Número 1). Universidad Central del Ecuador.
- Zednik, C. (2019). Solving the Black Box Problem: A Normative Framework for Explainable Artificial Intelligence. *Philosophy and Technology*. <https://doi.org/10.1007/s13347-019-00382-7>

**ANEXOS**


## **ANEXO 1**

### **Registro histórico de variables climáticas**


**Histogramas de precipitación diaria (mm) entre octubre de 2015 y enero de 2020**



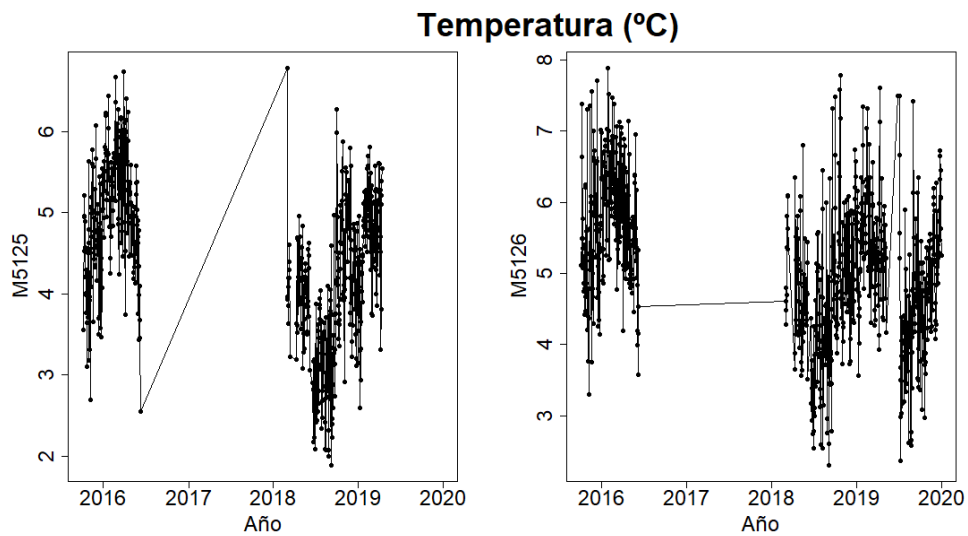
**Series de tiempo de humedad relativa diaria (%) entre octubre de 2015 y enero de 2020**



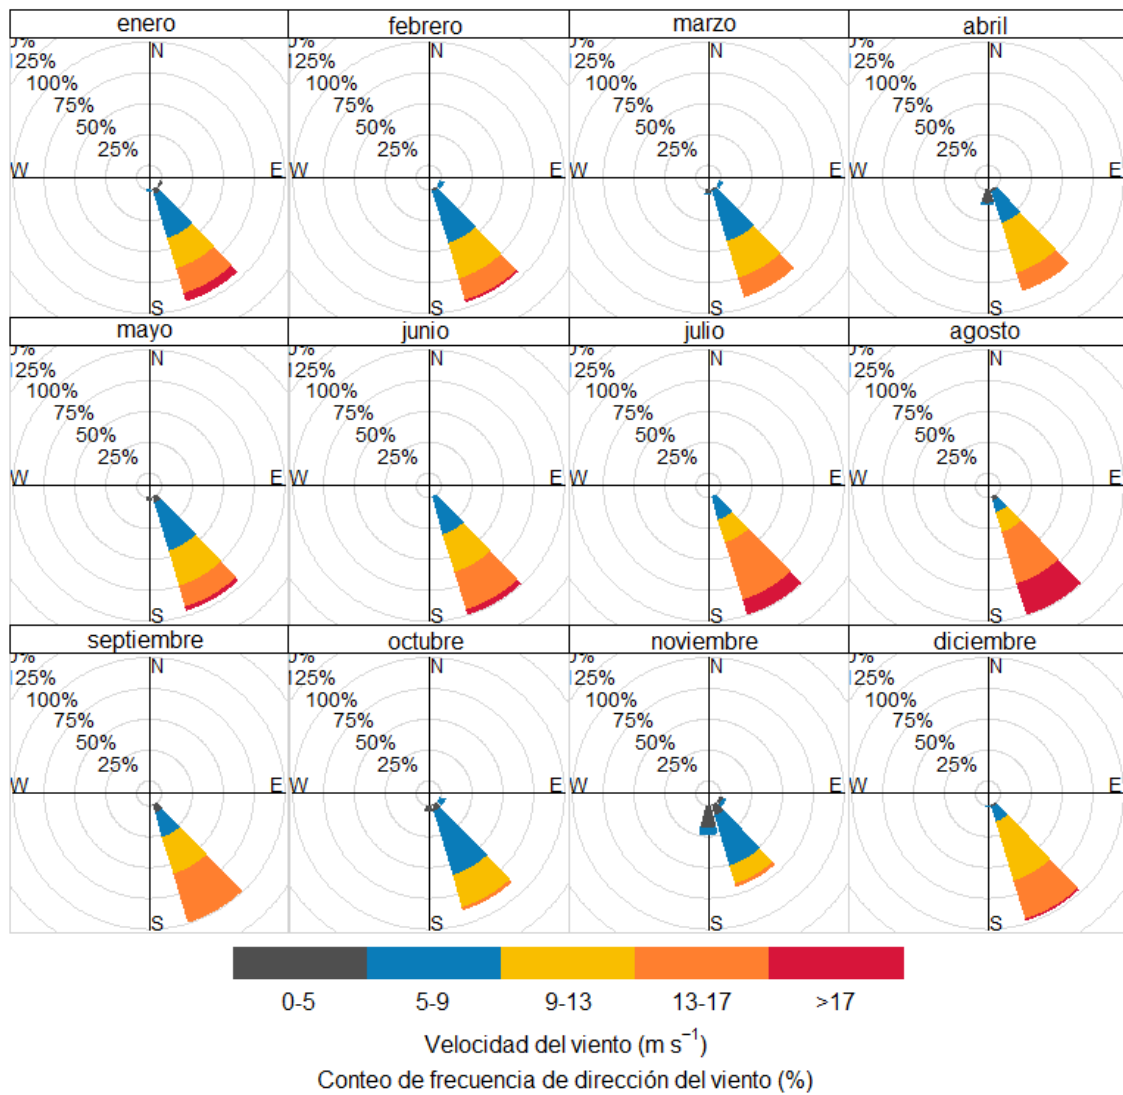
**Series de tiempo de presión atmosférica diaria (mbar) entre octubre de 2015 y enero de 2020**




**Series de tiempo de presión atmosférica diaria (mbar) entre octubre de 2015 y enero de 2020**



**Rosas de los vientos mensuales de la estación M5125 con datos de octubre de 2015 a enero de 2020**



**Rosas de los vientos mensuales de la estación M5126 con datos de octubre de 2015 a enero de 2020**





## **ANEXO 2**

### **Script de muestreo temporal**

```

1 ##### PIJ 17-05 #####
2 ##### INDEXES #####
3 ##### EPN #####
4 ##### David Carchipulla 04/05/2020 #####
5 ##### LAST MODIFIED 01/12/2020 #####
6
7 ##### System Requisistes #####
8 ##To clear environment and RAM
9 rm(list=ls())
10 gc()
11
12 ##To set Environment Variables - Time Zone
13 Sys.setenv(tz="UTC")
14
15
16 ###To install and to call packages
17 packages<-c('readxl','lubridate','dplyr','zoo','lattice','ggplot2','proto',
18            'ggpubr','tidyr','openair','geosphere','tidyr','gridExtra')
19
20 ipak <- function(pkg){
21   new.pkg <- pkg[!(pkg %in% installed.packages()[, "Package"])]
22   if (length(new.pkg))
23     install.packages(new.pkg, dependencies = TRUE)
24   sapply(pkg, require, character.only = TRUE)
25 }
26
27 ipak(packages)
28
29 ##### Calling Files #####
30
31 ##Surface to water level
32 manual_measurements<-data.frame(read_excel("./nf.xlsx",
33                                       col_types = c("date", "numeric", "numeric",
34                                                     "numeric", "numeric", "numeric",
35                                                     "numeric", "numeric", "numeric",
36                                                     "numeric", "numeric", "numeric",
37                                                     "numeric", "numeric", "numeric",
38                                                     "numeric", "numeric", "numeric",
39                                                     "numeric"), sheet = 'manual'))
40 auto_measurements<-data.frame(read_excel("./nf.xlsx",
41                                       col_types = c("date", "numeric", "numeric",
42                                                     "numeric"), sheet = 'automatico'))
43
44 ##Well bottom to water level
45 ##Caution: do not run these newxt two lines more than once
46 manual_measurements[,2:19]<-100+manual_measurements[,2:19]
47 auto_measurements[,2:3]<-100+auto_measurements[,2:3]
48
49 ##Transforming auto_measurements to daily data
50 daily_auto<-auto_measurements[,1:3] %>%
51   group_by(Daily = format(DATE, "%Y-%m-%d"))%>%
52   summarise_each(funs(mean=mean(., na.rm=T)))%>%
53   select(-DATE mean)
54 daily_auto[is.na(daily_auto)] <- NA ###Replacing NaN by NA
55 colnames(daily_auto)<-c('fecha','P6','P10')
56
57 ##Date Format
58 manual_measurements$fecha<-as.Date(manual_measurements$fecha,format = "%Y-%m-%d")
59 daily_auto$fecha<-as.Date(daily_auto$fecha,format = "%Y-%m-%d")
60
61 ##### Merging Data #####
62
63 ##Period of interest
64 fecha <- seq(as.POSIXlt('2016-01-01',tz = 'UTC', '%Y-%m-%d'),
65            as.POSIXlt('2019-12-31',tz = 'UTC', '%Y-%m-%d'), by='day')
66
67 ##Creating an empty data frame to be filled with actual data
68 wells<-data.frame(fecha,P1=NA,P2=NA,P3=NA,P4=NA,P5=NA,P6=NA,P7=NA,P8=NA,P9=NA,

```

```

69         P10=NA, P11=NA, P12=NA, P13=NA, P14=NA, P15=NA, P16=NA, P17=NA, P18=NA)
70
71     ##Filling Data Frame with automatic measurements
72     wells[paste(wells$fecha) %in% paste(daily_auto$fecha), ]$P6 = daily_auto$P6
73     wells[paste(wells$fecha) %in% paste(daily_auto$fecha), ]$P10 = daily_auto$P10
74
75     ##Filling and Replacing Data Frame with manual measurements
76     for (m in 2:ncol(manual_measurements)) {
77         wells[paste(wells$fecha) %in% paste(manual_measurements$fecha), m] =
78             manual_measurements[,m]
79     }
80     ##Replacing negative values by 0
81     for (r in 1:nrow(wells)) {
82         for (c in 2:ncol(wells)) {
83             if ((wells[r,c]<0) & (!is.na(wells[r,c]))) {
84                 wells[r,c]<-0
85             }
86         }
87     }
88
89     ##Reshaping data frame (WELLS) and visualizing data as a scatterplot
90     temp <- reshape(wells, direction="long", varying=2:19, sep="")
91
92     png('well_level.png',width = 1600,height = 800)
93
94     ggplot(temp, aes(x=fecha, y=P, color=as.factor(time))) +
95         geom_point(size=3.8) + scale_color_hue(h = c(90,180),l=80, c=70) +
96         labs(color = "Pozos de\ncontrol",x='Periodo de Estudio',y='Nivel freático (cm)') +
97         theme_bw() +
98         theme(legend.title=element_text(size=30),
99               legend.text=element_text(size=28),
100              text = element_text(size=30), panel.grid.major = element_blank(),
101              panel.grid.minor = element_blank()+border()+
102              guides(colour = guide_legend(ncol = 2))
103
104     dev.off()
105
106     ##Creating a zoo from data frame
107     zoo_nf<- zoo(wells[,-c(1)],
108                as.POSIXct(wells[,1],
109                            format ="%Y-%m-%d", tz="UTC"))
110
111     ##### ASSESSING RECHARGING THRESHOLD #####
112     ##Dataframe to register each threshold from wells' water level
113     thresholds<-data.frame(wells=c('P1','P2','P3','P4','P5','P6','P7','P8','P9',
114                                   'P10','P11','P12','P13','P14','P15','P16','P18','P18'),
115                            Q3=NA,median=NA,Q1=NA)
116
117     ##Thresholds computing
118     for (c in 1:ncol(zoo_nf)) {
119         thresholds[c,2]<-quantile(zoo_nf[,c],0.75,na.rm=T)
120         thresholds[c,3]<-median(zoo_nf[,c],na.rm=T)
121         thresholds[c,4]<-quantile(zoo_nf[,c],0.25,na.rm=T)
122     }
123
124     ##Thresholds' mean
125     Mthreshold<- data.frame(thresholds=c('q3','median','q1'),
126                             value=c(mean(thresholds$Q3),
127                                     mean(thresholds$median),
128                                     mean(thresholds$Q1)))
129
130
131     ##Plotting water level registered vs threshold
132     temp2<-temp
133     temp2$clase150<-NA
134     temp2$clase200<-NA
135     rownames(temp2) <- NULL

```

```

136
137 for (pozo in 1:length(temp2$P)) {
138   if (temp2[pozo,3]>=Mthreshold[1,2] & !is.na(temp2[pozo,3])){
139     temp2[pozo,5]<-113
140   }else if (temp2[pozo,3]<=Mthreshold[3,2] & !is.na(temp2[pozo,3])){ ##dates in q1
141     temp2[pozo,6]<-113
142   }
143 }
144
145 temp3<-temp2 %>% distinct(fecha,clase150, .keep_all = TRUE)
146
147 png('temp3.png',width = 1800,height = 800)
148 ggplot(data=temp2, aes(x=fecha, y=P, color=as.factor(time)))+
149   geom_col(data = temp3,aes(y=clase200),color='#40e0d0')+
150   geom_col(data = temp3,aes(y=clase150),color='#f4a460')+
151   geom_point(size=2.8) + scale_color_grey(start = 0.2, end = 0.2)+
152   labs(color = "Pozos de\ncontrol",x='Periodo de Estudio',y='Nivel freático (cm)') +
153   theme_bw() +
154   theme(legend.title=element_text(size=40),
155         legend.text=element_text(size=35),
156         text = element_text(size=40), panel.grid.major = element_blank(),
157         panel.grid.minor = element_blank()+border()+
158         guides(colour = guide_legend(ncol = 2))+
159         geom_hline(yintercept=Mthreshold[1,2],color='sienna3',size=1.5)+
160         geom_hline(yintercept=Mthreshold[3,2],color='turquoise3',size=1.5)+
161         geom_text(aes(x= temp[113,1]),
162                  label=paste('Umbral de recarga =',round(Mthreshold[1,2], 1),sep = ' '),
163                  y=mean(93), colour="black", size=10)+
164         geom_text(aes(x= temp[125,1]),
165                  label=paste('Umbral de descarga =',round(Mthreshold[3,2], 1),sep = ' '),
166                  y=mean(71), colour="black", size=10)
167 dev.off()
168
169
170 ##### EXPORTING RECHARGING DATES #####
171 ##empty df to separate dates by q3, meadian and q1
172 dates_empty<-data.frame(q3=NA,median=NA,q1=NA)
173 d<-1
174
175 for (c in 1:ncol(zoo_nf)) {
176   for (r in 1:nrow(zoo_nf)){
177     if (zoo_nf[r,c]>=Mthreshold[1,2] & !is.na(zoo_nf[r,c])){ ##dates in q3
178       dates_empty[d,1]<-as.character(index(zoo_nf[r,c]))
179       dates_empty[d,2]<-as.character(index(zoo_nf[r,c]))
180       d<-d+1
181     } else if (zoo_nf[r,c]>=Mthreshold[2,2] & !is.na(zoo_nf[r,c])){ ##dates in median
182       dates_empty[d,2]<-as.character(index(zoo_nf[r,c]))
183       d<-d+1
184     } else if (zoo_nf[r,c]<=Mthreshold[3,2] & !is.na(zoo_nf[r,c])){ ##dates in q1
185       dates_empty[d,3]<-as.character(index(zoo_nf[r,c]))
186       d<-d+1
187     }
188   }
189 }
190
191 ##Recharging dates are being separated
192 recharging_dates<-as.data.frame(dates_empty[,1])%>%
193   drop_na()%>% `colnames<-`(c('Fecha'))%>%
194   filter (! duplicated(Fecha))%>%
195   `rownames<-`(NULL)
196
197 ##Drought dates are being separated
198 drought_dates<-as.data.frame(dates_empty[,3])%>%
199   drop_na()%>% `colnames<-`(c('Fecha'))%>%
200   filter (! duplicated(Fecha))%>%
201   `rownames<-`(NULL)
202
203 ##Dates are saved as a csv

```



```

204 write.csv(recharging_dates,'recharging_dates.csv',row.names = F)
205 write.csv(drought_dates,'drought_dates.csv',row.names = F)
206
207 ##All registered dates are being save as a new vector
208 cDates<-wells
209 cDates<- cDates[complete.cases(cDates[, 11]),]
210 cDates<-cDates%>%
211   select(-c(2:19))
212
213 ##All dates but recharging dates are being saved as a df
214 remove<-recharging_dates$Fecha
215 remove<-as.Date(remove, format = "%Y-%m-%d")
216 cDates<-as.Date(cDates$fecha, format = "%Y-%m-%d")
217 notRecharging<-as.data.frame(cDates [! cDates %in% remove])%>%
218   `colnames<-`(c('Fecha'))%>%
219   `rownames<-`(NULL)
220
221 ##All dates but recharging dates are being exported as a csv
222 write.csv(notRecharging,'notRecharging_dates.csv',row.names = F)
223
224 ##### Calling DATA LOGGER Files #####
225
226 ##METEROLOGICAL VARIABLES ARE BEING READ
227 dat_HR<- read_excel("./data/HR.xlsx",
228                   col_types = c("date", "numeric",
229                                "numeric"), na = c("null",''))
230
231 dat_P<- read_excel("./data/P.xlsx",
232                   col_types = c("date", "numeric",
233                                "numeric"), na = c("null",''))
234
235 dat_PRECIP<- read_excel("./data/PRECIP.xlsx",
236                        col_types = c("date", "numeric",
237                                     "numeric"), na = c("null",''))
238
239 dat_T<- read_excel("./data/T.xlsx",
240                   col_types = c("date", "numeric",
241                                "numeric"), na = c("null",''))
242
243 dat_WD<- read_excel("./data/WD.xlsx",
244                   col_types = c("date", "numeric",
245                                "numeric"), na = c("null",''))
246
247 dat_WS<- read_excel("./data/WS.xlsx",
248                   col_types = c("date", "numeric",
249                                "numeric"), na = c("null",''))
250
251 est<- data.frame(read_excel("./data/est.xlsx",
252                           col_types = c("numeric", "numeric",
253                                          "numeric",'text',
254                                          'text')))
255
256 ##### DATA CLEANSING #####
257 ##All VARIABLES WERE BEING SET AS A DF AND PROPERTIES WERE BEING DEFINED
258 ## NEGATIVE VALUES WERE SET AS NA
259 ## HOURLY DATA BECAME DAILY DATA
260 ## COLNAMES ARE DEFINED ACCORDINGLY TO SATATION MEASURED
261 ## NaN PASSED TO NA
262 dat_HR<-as.data.frame(dat_HR %>%
263   mutate_each(funs(replace(., .<0, NA)))%>%
264   group_by(Daily = format(FECHA, "%Y-%m-%d"))%>%
265   summarise_each(funs(mean=mean(., na.rm=T)))%>%
266   select(-c(FECHA_mean))%>%
267   `colnames<-`(c('fecha',"M5125", "M5126"))%>%
268   replace(., .=='NaN', NA))
269
270 dat_P<-as.data.frame(dat_P %>%
271   mutate_each(funs(replace(., .<0, NA)))%>%

```

```

272     group_by(Daily = format(FECHA, "%Y-%m-%d")) %>%
273     summarise_each(funs(mean=mean(., na.rm=T))) %>%
274     select(-c(FECHA_mean)) %>%
275     `colnames<-`(c('fecha', "M5125", "M5126")) %>%
276     replace(., .=='NaN', NA)
277
278 dat_PRECIP<-as.data.frame(dat_PRECIP %>%
279     mutate_each(funs(replace(., .<0, NA))) %>%
280     group_by(Daily = format(FECHA, "%Y-%m-%d")) %>%
281     summarise_each(funs(sum=sum(., na.rm=T), -FECHA)) %>%
282     `colnames<-`(c('fecha', "M5125", "M5126")) %>%
283     replace(., .=='NaN', NA)
284
285 dat_T<-as.data.frame(dat_T %>%
286     mutate_each(funs(replace(., .<0, NA))) %>%
287     group_by(Daily = format(FECHA, "%Y-%m-%d")) %>%
288     summarise_each(funs(mean=mean(., na.rm=T))) %>%
289     select(-c(FECHA_mean)) %>%
290     `colnames<-`(c('fecha', "M5125", "M5126")) %>%
291     replace(., .=='NaN', NA)
292
293 dat_WD<-as.data.frame(dat_WD %>%
294     mutate_each(funs(replace(., .<0, NA))) %>%
295     group_by(Daily = format(FECHA, "%Y-%m-%d")) %>%
296     summarise_each(funs(mean=mean(., na.rm=T))) %>%
297     select(-c(FECHA_mean)) %>%
298     `colnames<-`(c('fecha', "M5125", "M5126")) %>%
299     replace(., .=='NaN', NA)
300
301 dat_WS<-as.data.frame(dat_WS %>%
302     mutate_each(funs(replace(., .<0, NA))) %>%
303     group_by(Daily = format(FECHA, "%Y-%m-%d")) %>%
304     summarise_each(funs(mean=mean(., na.rm=T))) %>%
305     select(-c(FECHA_mean)) %>%
306     `colnames<-`(c('fecha', "M5125", "M5126")) %>%
307     replace(., .=='NaN', NA)
308
309 ### FINDING AND REMOVING OUTLIERS
310 for (v in 2:ncol(dat_HR)) {
311     ###FINDING OUTLIERS
312     outliers <- boxplot(dat_HR[,v], plot=FALSE)$out
313     ##ELIMINATING OUTLIERS
314     dat_HR<- dat_HR[-which(dat_HR[,v] %in% outliers),]
315 }
316
317 ### FINDING AND REMOVING OUTLIERS
318 for (v in 2:3) {
319     ###FINDING OUTLIERS
320     outliers <- boxplot(dat_P[,v], plot=FALSE)$out
321     ##ELIMINATING OUTLIERS
322     dat_P<- dat_P[-which(dat_P[,v] %in% outliers),]
323 }
324
325
326 ##NOT OUTLIERS
327 ##for (v in 2:3) {
328     ###FINDING OUTLIERS
329     #outliers <- boxplot(dat_PRECIP[,v], plot=FALSE)$out
330     ##ELIMINATING OUTLIERS
331     #dat_PRECIP<- dat_PRECIP[-which(dat_PRECIP[,v] %in% outliers),]
332     ##}
333
334 for (v in 2:ncol(dat_T)) {
335     ###FINDING OUTLIERS
336     outliers <- boxplot(dat_T[,v], plot=FALSE)$out
337     ##ELIMINATING OUTLIERS
338     dat_T<- dat_T[-which(dat_T[,v] %in% outliers),]
339 }

```

```

340
341
342 W_M5125<-data.frame(dat_WS$fecha,dat_WS$M5125,dat_WD$M5125)
343 W_M5126<-data.frame(dat_WS$fecha,dat_WS$M5126,dat_WD$M5126)
344
345
346
347 ###FINDING OUTLIERS
348 outliers <- boxplot(W_M5125[,3], plot=FALSE)$out
349 ##ELIMINATING OUTLIERS
350 W_M5125<- W_M5125[-which(W_M5125[,3] %in% outliers),]
351
352
353 ###FINDING OUTLIERS
354 outliers <- boxplot(W_M5126[,3], plot=FALSE)$out
355 ##ELIMINATING OUTLIERS
356 W_M5126<- W_M5126[-which(W_M5126[,3] %in% outliers),]
357
358
359 ##### PLOT CLEANSED DATA #####
360 p <- proto(plot.zoo = plot.zoo, mtext = function(...)
361 graphics::mtext(..., cex = 2)) ##Changind plot.zoo cex
362
363
364 zoo_HR<-read.zoo(dat_HR, format = "%Y-%m-%d")
365 png('HR.png',width = 1200,height = 600)
366 with(p, plot.zoo)(zoo_HR, plot.type = "multiple", nc=2,
367 oma=c(4,6,3,0), mar = c(0.7,1.5,0.7,7), xlab = "Año",
368 main = 'Humedad Relativa (%)',type = "o",
369 cex.axis = 2, cex.main=3, pch = 19)
370 dev.off()
371
372 zoo_P<-read.zoo(dat_P, format = "%Y-%m-%d")
373 png('Pressure.png',width = 1200,height = 600)
374 with(p, plot.zoo)(zoo_P, plot.type = "multiple", nc=2,
375 oma=c(4,6,3,0), mar = c(0.7,1.5,0.7,7), xlab = "Año",
376 main = 'Presión atmosférica (mbar)',type = "o",
377 cex.axis = 2, cex.main=3, pch = 19)
378 dev.off()
379
380 zoo_PRECIP<-read.zoo(dat_PRECIP, format = "%Y-%m-%d")
381 par(mar=c(5,5,3,0))
382 png('Precip_M5125.png',width = 1200,height = 600)
383 par(mar=c(5,5,3,0))
384 hist(zoo_PRECIP$M5125, main = 'M5125', xlab = 'Precipitación (mm)',breaks = 5,
385 cex.axis = 2, cex.main=3,cex.lab=2, ylab='Frecuencia')
386 dev.off()
387
388 png('Precip_M5126.png',width = 1200,height = 600)
389 par(mar=c(5,5,3,0))
390 hist(zoo_PRECIP$M5126, main = 'M5126', xlab = 'Precipitación (mm)',breaks = 5,
391 cex.axis = 2, cex.main=3,cex.lab=2, ylab='Frecuencia')
392 dev.off()
393
394 png('Precip.png',width = 1200,height = 600)
395 with(p, plot.zoo)(zoo_PRECIP, plot.type = "multiple", nc=2,
396 oma=c(4,6,3,0), mar = c(0.7,1.5,0.7,7), xlab = "Año",
397 main = 'Precipitación (mm)',type = "p",
398 cex.axis = 2, cex.main=3, pch = 19)
399 dev.off()
400
401 zoo_T<-read.zoo(dat_T, format = "%Y-%m-%d")
402 par(no.readonly = TRUE)
403 png('Temperature.png',width = 1200,height = 600)
404 with(p, plot.zoo)(zoo_T, plot.type = "multiple", nc=2,
405 oma=c(4,6,3,0), mar = c(0.7,1.5,0.7,7), xlab = "Año",
406 main = 'Temperatura (°C)',type = "o",
407 cex.axis = 2, cex.main=3, pch = 19)

```



```

408 dev.off()
409
410 png('WR5125.png',width = 1200,height = 600)
411 windRose(W_M5125,ws='dat_WS.M5125',
412          wd='dat_WD.M5125', width = 10,
413          breaks = c(0,5,9,13,17,30),
414          paddle = F,annotate = F,grid.line = 25,
415          key=list(labels=c('0-5',
416                           '5-9',
417                           '9-13',
418                           '13-17',
419                           '>17')),
420          key.header = 'Velocidad del viento (m·s-1)',
421          key.footer = 'Conteo de frecuencia de dirección del viento (%)',
422          key.position = 'bottom',
423          par.settings=list(axis.line=list(col='lightgray'),
424                           fontsize=list(text=20)),
425          col = c('#4f4f4f','#0a7cb9','#f9be00','#ff7f2f','#d7153a'))
426 dev.off()
427
428 png('WR5126.png',width = 1200,height = 600)
429 windRose(W_M5126,ws='dat_WS.M5126',
430          wd='dat_WD.M5126', width = 10,
431          breaks = c(0,3,6,9,12,15),
432          paddle = F,annotate = F,grid.line = 25,
433          key=list(labels=c('0-3',
434                           '3-6',
435                           '6-9',
436                           '9-12',
437                           '>12')),
438          key.header = 'Velocidad del viento (m·s-1)',
439          key.footer = 'Conteo de frecuencia de dirección del viento (%)',
440          key.position = 'bottom',
441          par.settings=list(axis.line=list(col='lightgray'),
442                           fontsize=list(text=20)),
443          col = c('#4f4f4f','#0a7cb9','#f9be00','#ff7f2f','#d7153a'))
444 dev.off()
445
446
447
448 ##### MERGE DATA IN A SINGLE DATA FRAME USING WAM #####
449 ### Weighted arithmetic mean
450 WAM<-data.frame(estaciones=c('M5125','M5126'),
451                peso=c(distm(c(est[1,1], est[1,2]),
452                             c(est[3,1], est[3,2]), fun = distHaversine),
453                       distm(c(est[2,1], est[2,2]),
454                             c(est[3,1], est[3,2]), fun = distHaversine)))
455
456 ##Period of interest
457 daily <- seq(as.POSIXlt('2015-10-05',tz = 'UTC', '%Y-%m-%d'),
458             as.POSIXlt('2019-12-31',tz = 'UTC', '%Y-%m-%d'), by='1 day')
459
460 ##Creating an empty data frame to be filled with actual data
461 HR<-data.frame(daily,M5125=NA,M5126=NA)
462 P<-data.frame(daily,M5125=NA,M5126=NA)
463 PRECIP<-data.frame(daily,M5125=NA,M5126=NA)
464 TEMP<-data.frame(daily,M5125=NA,M5126=NA)
465 WD<-data.frame(daily,M5125=NA,M5126=NA)
466 WS<-data.frame(daily,M5125=NA,M5126=NA)
467
468
469 ##Filling Data Frame with measurements
470 HR[paste(HR$daily) %in% paste(dat_HR$fecha), ]$M5125 = dat_HR$M5125
471 HR[paste(HR$daily) %in% paste(dat_HR$fecha), ]$M5126 = dat_HR$M5126
472
473 P[paste(P$daily) %in% paste(dat_P$fecha), ]$M5125 = dat_P$M5125
474 P[paste(P$daily) %in% paste(dat_P$fecha), ]$M5126 = dat_P$M5126
475

```



```

476 PRECIP[paste(PRECIP$daily) %in% paste(dat_PRECIP$fecha), ]$M5125 = dat_PRECIP$M5125
477 PRECIP[paste(PRECIP$daily) %in% paste(dat_PRECIP$fecha), ]$M5126 = dat_PRECIP$M5126
478
479 TEMP[paste(TEMP$daily) %in% paste(dat_T$fecha), ]$M5125 = dat_T$M5125
480 TEMP[paste(TEMP$daily) %in% paste(dat_T$fecha), ]$M5126 = dat_T$M5126
481
482 WD[paste(WD$daily) %in% paste(dat_WD$fecha), ]$M5125 = dat_WD$M5125
483 WD[paste(WD$daily) %in% paste(dat_WD$fecha), ]$M5126 = dat_WD$M5126
484
485 WS[paste(WS$daily) %in% paste(dat_WS$fecha), ]$M5125 = dat_WS$M5125
486 WS[paste(WS$daily) %in% paste(dat_WS$fecha), ]$M5126 = dat_WS$M5126
487
488
489 ###SINGLE DATA FRAME
490 feed<-data.frame(daily,HR_percent=NA,P_mbar=NA,PRECIP_mm=NA,
491                 T_C=NA,WD_degree=NA,WS_m_s=NA)
492
493 for (r in 1:nrow(feed)) {
494   feed[r,2]<-weighted.mean(HR[r,2:3],WAM[,2],na.rm = T)
495 }
496 for (r in 1:nrow(feed)) {
497   feed[r,3]<-weighted.mean(P[r,2:3],WAM[,2],na.rm = T)
498 }
499 for (r in 1:nrow(feed)) {
500   feed[r,4]<-weighted.mean(PRECIP[r,2:3],WAM[,2],na.rm = T)
501 }
502 for (r in 1:nrow(feed)) {
503   feed[r,5]<-weighted.mean(TEMP[r,2:3],WAM[,2],na.rm = T)
504 }
505 for (r in 1:nrow(feed)) {
506   feed[r,6]<-weighted.mean(WD[r,2:3],WAM[,2],na.rm = T)
507 }
508 for (r in 1:nrow(feed)) {
509   feed[r,7]<-weighted.mean(WS[r,2:3],WAM[,2],na.rm = T)
510 }
511 ##### PLOTTING MERGED DATA #####
512 feed_complete<-feed %>%
513   drop_na() %>%
514   `colnames<-`(c('fecha',"Humedad Relativa (%)", "Presión atmosférica (mbar)",
515                 "Precipitación (mm)",'Temperatura (°C)',
516                 'Dirección del Viento (°)',
517                 'Velocidad del Viento (m·s-1)'))
518
519 ###EXPORTING WEATHER DATA
520 write.csv(feed_complete,'./feed_complete.csv',row.names = F)
521
522 gfeed<-reshape(feed_complete, varying = list(2:5),direction = 'long',
523               v.names = 'WV')
524
525 var<-data.frame(v1=1:4,
526                v2=c("Humedad Relativa (%)", "Presión atmosférica (mbar)",
527                    "Precipitación (mm)",'Temperatura (°C)'))
528
529 gfeed<-merge(gfeed, var, by.x='time', by.y="v1")
530
531 png('GFEED.png',width = 1200,height = 800)
532 gfeed %>%
533   ggplot(aes(x = fecha, y = WV)) +
534   geom_point() + geom_line()+
535   facet_wrap(~ v2, scales = "free") +
536   xlab("Periodo de estudio") + ylab("Variables utilizadas")+
537   theme(text = element_text(size=30))
538 dev.off()
539
540 png('WR.png',width = 1200,height = 600)
541 windRose(feed_complete,ws='Velocidad del Viento (m·s-1)',
542          wd='Dirección del Viento (°)', width = 10,
543          breaks = c(0,3,6,9,12,15),

```

```

544     paddle = F, annotate = F, grid.line = 25,
545     key=list(labels=c('0-3',
546                     '3-6',
547                     '6-9',
548                     '9-12',
549                     '>12')),
550     key.header = 'Velocidad del viento (m·s-1)',
551     key.footer = 'Conteo de frecuencia de dirección del viento (%)',
552     key.position = 'bottom',
553     par.settings=list(axis.line=list(col='lightgray'),
554                      fontsize=list(text=20)),
555     col = c('#4f4f4f', '#0a7cb9', '#f9be00', '#ff7f2f', '#d7153a'))
556 dev.off()
557
558 ##### MAKING TIME CLASSIFICATION SAMPLE #####
559 ### MAKING A SAMPLE DATA FRAME
560 sample<-data.frame(feed complete, class=NA)
561 rownames(sample)<-1:nrow(sample)
562 colnames(sample)<- c('fecha', "Humedad Relativa (%)", "Presión atmosférica (mbar)",
563                    "Precipitación (mm)", "Temperatura (°C)",
564                    "Dirección del Viento (°)",
565                    'Velocidad del Viento (m·s-1)', 'class')
566 sample$fecha<-as.character(sample$fecha)
567
568 ### UPLOADING DATES REGISTERED AS NEAR GROUND SATURATION
569 rechargingDates<-recharging_dates
570 rechargingDates$Fecha<-as.character(rechargingDates$Fecha)
571
572 notRechargingDates<-drought_dates
573 notRechargingDates$x<-as.character(drought_dates$Fecha)
574
575 ####CLASSIFYING ACCORDING TO WATER LEVEL REGISTER
576 for (date in 1:nrow(sample)) {
577   for (rd in 1:nrow(rechargingDates)) {
578     for (nrd in 1:nrow(notRechargingDates)) {
579       if (sample[date,1]==rechargingDates[rd,1]){
580         sample[date,8]<-0 ##0 = class(near saturation)
581       } else if (sample[date,1]==notRechargingDates[nrd,1]){
582         sample[date,8]<-1 ##1 = class(not near saturation)
583       }
584     }
585   }
586 }
587
588 ### DROPPING NOT USED DATES TO CREATE THE SAMPLE
589 train<-sample %>%
590   drop na()%>%
591   `rownames<-`(NULL)
592
593 ###EXPORTING SAMPLE AND TRAINING DATA
594 write.csv(train, './train.csv', row.names = F)
595 write.csv(sample, './sample.csv', row.names = F)
596
597
598
599 ###DESCRIBING MONTHLY WEATHER DATA
600 monthly<-data.frame(feed_complete, day=NA, month=NA)
601 monthly$day <- format(as.Date(monthly$fecha), "%d")
602 monthly$month <- format(as.Date(monthly$fecha), "%m")
603
604 m_precip<-aggregate( Precipitación..mm. ~ day + month , monthly, mean )
605 m_t<-aggregate( Temperatura..°C. ~ day + month , monthly, mean )
606 m_h<-aggregate( Humedad.Relativa... ~ day + month , monthly, mean )
607 m_p<-aggregate( Presión.atmosférica..mbar. ~ day + month , monthly, mean )
608 m_ws<-aggregate( Velocidad.del.Viento..m.s.l. ~ day + month , monthly, mean )
609 m_wd<-aggregate( Dirección.del.Viento..°. ~ day + month , monthly, mean )
610
611 m_precip<-aggregate( Precipitación..mm. ~ month , m_precip, sum )

```

```

612 m_t<-aggregate( Temperatura..°C. ~ month , m_t, mean )
613 m_h<-aggregate( Humedad.Relativa.... ~ month , m_h, mean )
614 m_p<-aggregate( Presión.atmosférica..mbar. ~ month , m_p, mean )
615 m_ws<-aggregate( Velocidad.del.Viento..m.s.l. ~ month , m_ws, mean )
616 m_wd<-aggregate( Dirección.del.Viento..°. ~ month , m_wd, mean )
617
618
619 bim<-data.frame(m_precip$month,m_precip$Precipitación..mm.,m_t$Temperatura..°C.,
620                m_h$Humedad.Relativa...., m_p$Presión.atmosférica..mbar.,
621                m_ws$Velocidad.del.Viento..m.s.l.,m_wd$Dirección.del.Viento..°. )
622
623 colors <- c( "Temperatura" = "orange3", 'Precipitación'='#999999')
624 colors2<-c( "Presión" = "orange3", 'Humedad Relativa'='#999999')
625 colors3<-c( "Velocidad" = "orange3", 'Dirección'='#999999')
626
627 png('precip_vs_temp.png',width = 1200,height = 800)
628 ggplot(bim, aes(x=m_precip.month, group = 1)) +
629
630     geom_area(aes(y=m_t.Temperatura..°C.*5,color='Temperatura'), fill='orange3') + #
631     Divide by 10 to get the same range than the temperature
632     geom_col(aes(y=m_precip.Precipitación..mm.,color='Precipitación'),fill="#999999") +
633
634     scale_y_continuous(
635
636         # Features of the first axis
637         name = "Precipitación (mm)",
638
639         # Add a second axis and specify its features
640         sec.axis = sec_axis(~./5, name="Temperatura °C")
641     )+
642     labs(x='Mes',color='Leyenda') +
643     scale_color_manual(values = colors)+
644     theme_bw() +
645     theme(legend.position = c(0.12, 0.9),legend.title=element_text(size=25),
646           legend.text=element_text(size=25),
647           text = element_text(size=30), panel.grid.major = element_blank(),
648           panel.grid.minor = element_blank()+border()+
649           guides(color = guide_legend(ncol = 1))
650     dev.off()
651
652 png('press_vs_hr.png',width = 1200,height = 800)
653 ggplot(bim, aes(x=m_precip.month, group = 1)) +
654
655     geom_area(aes(y=m_p.Presión.atmosférica..mbar./10,color='Presión atmosférica'),
656             fill='orange3') + # Divide by 10 to get the same range than the temperature
657     geom_col(aes(y=m_h.Humedad.Relativa...., color='Humedad relativa'),fill="#999999") +
658
659     scale_y_continuous(
660         limits=c(0,110),
661         # Features of the first axis
662         name = "Humedad relativa (%)",
663
664         # Add a second axis and specify its features
665         sec.axis = sec_axis(~.*10, name="Presión atmosférica (mbar)")
666     )+
667     labs(x='Mes',color='Leyenda') +
668     scale_color_manual(values = colors2)+
669     theme_bw() +
670     theme(legend.position = c(0.15, 0.9),legend.title=element_text(size=25),
671           legend.text=element_text(size=25),
672           text = element_text(size=30), panel.grid.major = element_blank(),
673           panel.grid.minor = element_blank()+border()+
674           guides(color = guide_legend(ncol = 1))
675     dev.off()
676
677 png('ws_vs_wd.png',width = 1200,height = 800)
678 ggplot(bim, aes(x=m_precip.month, group = 1)) +

```

```
678
679 geom_area(aes(y=m_ws.Velocidad.del.Viento..m.s.1.*10,color='Velocidad del
        viento'), fill='orange3') + # Divide by 10 to get the same range than the
        temperature
680 geom_col(aes(y=m_wd.Dirección.del.Viento..°, color='Dirección del
        viento'),fill="#999999") +
681
682 scale_y_continuous(
683   limits=c(0,210),
684   # Features of the first axis
685   name = "Dirección del viento (°)",
686
687   # Add a second axis and specify its features
688   sec.axis = sec_axis(~./10, name="Velocidad del viento (m·s-1)")
689 )+
690 labs(x='Mes',color='Leyenda') +
691 scale_color_manual(values = colors3)+
692 theme_bw() +
693 theme(legend.position = c(0.15, 0.9),legend.title=element_text(size=25),
694       legend.text=element_text(size=25),
695       text = element_text(size=30), panel.grid.major = element_blank(),
696       panel.grid.minor = element_blank()+border()+
697       guides(color = guide_legend(ncol = 1))
698 dev.off()
699
700
```

### **ANEXO 3**

**Script de clasificación y evaluación temporal**



```

1 ##### PIJ 17-05 #####
2 ##### INDEXES #####
3 ##### EPN #####
4 ##### David Carchipulla #####
5
6 ##### ELABORATED: 23/05/2020
7 ##### LAST MODIFIED: 12/7/2020
8
9 ##### System Requisistes #####
10 ##To clear environment and RAM
11 rm(list=ls())
12 gc()
13
14 ##To set Environment Variables - Time Zone
15 Sys.setenv(tz="UTC")
16
17
18 ###To install and to call packages
19 packages<-c('randomForest','corrplot','ggcorrplot',
20             'ggpubr','tibble','data.table','ranger',
21             'tm','tidyr','gttools','dplyr','caret',
22             'party','partykit')
23
24 ipak <- function(pkg){
25   new.pkg <- pkg[!(pkg %in% installed.packages()[, "Package"])]
26   if (length(new.pkg))
27     install.packages(new.pkg, dependencies = TRUE)
28   sapply(pkg, require, character.only = TRUE)
29 }
30
31 ipak(packages)
32 ##### CONSTRUCTION 1 #####
33 ###UPLOADING TRAIN DATA AND SAMPLE
34 sample<-read.csv('./sample.csv') ###NA IN CLASS
35 train<-read.csv('./train.csv') ###NO NA IN CLASS
36 ###A DAY OF THE YEAR COLUMN IS ADDED
37 train$fecha<-as.POSIXct(train$fecha,tz = 'UTC', '%Y-%m-%d')
38 train<-cbind(train[,1:7],DOY=yday(train$fecha),train[,8])
39
40 sample$fecha<-as.POSIXct(sample$fecha,tz = 'UTC', '%Y-%m-%d')
41 sample<-cbind(sample[,1:7],DOY=yday(sample$fecha),sample[,8])
42
43 ### COLNAMES ARE SHORTENED
44 colnames(train)<-c('FECHA','HR','PA','PRECIP','T','WD','WS',
45                  'DOY','CLASS')
46
47 colnames(sample)<-c('FECHA','HR','PA','PRECIP','T','WD','WS',
48                   'DOY','CLASS')
49
50 ### CLASS SHALL BE A FACTOR
51 train$CLASS<-as.factor(train$CLASS)
52 sample$CLASS<-as.factor(sample$CLASS)
53
54 ## VARIABLES' CORRELATION
55 data_corr<- sample %>% dplyr ::select(-!c(1,9)) %>% cor()
56 col <- colorRampPalette(c("#BB4444", "#EE9988", "#FFFFFF", "#77AADD", "#4477AA"))
57
58 png('corplot.png',width = 800,height = 800, pointsize = 25)
59 corrplot(data_corr, method = "color", col = col(200),
60          type = "upper", order = "hclust", number.cex = .7,
61          addCoef.col = "black", # Add coefficient of correlation
62          tl.col = "black", tl.srt = 90, # Text label color and rotation
63          # Combine with significance
64          sig.level = 0.01, insig = "blank",
65          # hide correlation coefficient on the principal diagonal
66          diag = FALSE)
67 dev.off()
68

```

```

69 #ggcorrplot(data_corr, method = c("square"),type = c("lower"),
70 #          ggtheme = ggplot2::theme_classic(base_size = 11, base_line_size= 0.2),
71 #          title = "",
72 #          show.legend = TRUE, legend.title = "Corr", show.diag = FALSE,
73 #          colors = c("#A90B09", "white", "#2889ce"),
74 #          outline.color = "#F5F1F1",
75 #          hc.order = TRUE, hc.method = "complete", lab = TRUE,
76 #          lab_col = "black", lab_size = 3, sig.level = 0.01,
77 #          insig = c("blank"),
78 #          tl.cex = 10, tl.col = "black", tl.srt = 90,
79 #          digits = 2)+
80 # theme(axis.title.x = element_text(angle=0,hjust=-0.12,vjust=14,size=10))+
81 # labs(x = "Variables")
82
83 # TREE NUMBER ASSESSMENT
84 fun_ntree <- function(num){
85   res <- lapply(seq_len(num), function(i){
86     rf <- ranger(formula = as.formula(CLASS~.), data = train[,2:9], num.trees = i,
87                 mtry = 3, importance = "impurity", write.forest = T, probability = T,
88                 min.node.size = floor(0.02*nrow(train[,2:9])));
89     rf$prediction.error
90   })
91   return(unlist(res))
92 }
93
94 res_ntree <- data.table(Arboles=seq(1,2000), OOB=fun_ntree(2000))
95
96 png('OOBvsTREEN.png',width = 1600,height = 800)
97 ggplot(data = res_ntree, aes(x = Arboles, y = OOB)) + geom_line() +
98   labs(title = "Evolución del OOB vs Número Árboles", x = "Nº árboles") +
99   theme_bw()+theme(legend.title=element_text(size=30),
100                  legend.text=element_text(size=28),
101                  text = element_text(size=30))
102 dev.off()
103
104 #IT IS STABILIZED SINCE THE 1000TH TREE
105 set.seed(1234)
106 modelo_randforest <- randomForest(formula = CLASS ~ . ,
107                                   data = train[,2:9],
108                                   mtry = 3,
109                                   importance = T,
110                                   ntree = 1000,
111                                   keep.forest = T)
112
113 importancia <- as.data.frame(modelo_randforest$importance)
114 importancia <- rownames to column(importancia,var = "variable")
115 colnames(importancia)<-c('variable', 'MeanDecreaseAccuracy', 'MeanDecreaseGini')
116
117 p1 <- ggplot(data = importancia, aes(x = reorder(variable, MeanDecreaseAccuracy),
118                                     y = MeanDecreaseAccuracy,
119                                     fill = MeanDecreaseAccuracy)) +
120   labs(x = "Variable", title = element_blank(),y = "Mean Decrease Accuracy") +
121   geom_col() + coord_flip() +
122   theme(axis.text.x = element_text(angle = 0, hjust = 0.5, size = 10),
123         axis.text.y = element_text(size = 10),
124         axis.title.x = element_text(size = 10),
125         axis.title.y = element_text(size = 10) )+ theme_bw()+
126   theme(legend.position = "bottom", legend.title=element_blank())+
127   scale_fill_gradient(low="grey44", high="lightgrey")+
128   guides(fill = guide_colourbar(barwidth = 10))
129
130 p2 <- ggplot(data = importancia, aes(x = reorder(variable, MeanDecreaseGini),
131                                     y = MeanDecreaseGini,
132                                     fill = MeanDecreaseGini)) +
133   labs(x = "", title = element_blank(), y="Mean Decrease Gini")+ #x="Variable"
134   geom_col() +coord_flip() + theme_bw() +
135   theme(legend.position = "bottom", legend.title=element_blank())+

```

```

136   scale_fill_gradient(low="grey44", high="lightgrey")+
137   guides(fill = guide_colourbar(barwidth = 10))
138
139
140 ## Gráfica de RF
141 #ggarrange(p1, p2, ncol=2, nrow=1, legend = "bottom",
142 #          common.legend = F, align = "none", widths = c(1.03,1), labels = "auto",
143 #          font.label = list(size = 9, color = "black", family = NULL))
144
145 png('importance.png', width = 600, height = 400)
146 ggarrange(p1, p2)
147 dev.off()
148
149 ##### CONSTRUCTION 2 #####
150 # TREE NUMBER ASSESSMENT
151 fun_ntree_2 <- function(num) {
152   res <- lapply(seq len(num), function(i) {
153     rf <- ranger(formula = as.formula(CLASS~.), data = train[,c(2:6,8,9)], num.trees
154                 = i,
155                 mtry = 3, importance = "impurity", write.forest = T, probability = T,
156                 min.node.size = floor(0.02*nrow(train[,c(2:6,8,9)])));
157     rf$prediction.error
158   })
159   return(unlist(res))
160 }
161 res_ntree_2 <- data.table(Arboles=seq(1,2000), OOB=fun_ntree_2(2000))
162
163 png('OOBvsTREEN 2.png', width = 1600, height = 800)
164 ggplot(data = res_ntree_2, aes(x = Arboles, y = OOB)) + geom_line() +
165   labs(title = "Evolución del OOB vs Número Árboles", x = "Nº árboles") +
166   theme_bw()+theme(legend.title=element_text(size=30),
167                   legend.text=element_text(size=28),
168                   text = element_text(size=30))
169 dev.off()
170
171 #IT IS STABILIZED SINCE THE 1250TH TREE
172 set.seed(6789)
173 modelo_randforest_2 <- randomForest(formula = CLASS ~ .,
174                                   data = train[,c(2:6,8,9)],
175                                   mtry = 3,
176                                   importance = T,
177                                   ntree = 1250,
178                                   keep.forest = T)
179
180 importancia_2 <- as.data.frame(modelo_randforest_2$importance)
181 importancia_2 <- rownames to column(importancia_2, var = "variable")
182 colnames(importancia_2) <- c('variable', 'MeanDecreaseAccuracy', 'MeanDecreaseGini')
183
184 p3 <- ggplot(data = importancia_2, aes(x = reorder(variable, MeanDecreaseAccuracy),
185                                       y = MeanDecreaseAccuracy,
186                                       fill = MeanDecreaseAccuracy)) +
187   labs(x = "Variable", title = element_blank(), y = "Mean Decrease Accuracy") +
188   geom_col() + coord_flip() +
189   theme(axis.text.x = element_text(angle = 0, hjust = 0.5, size = 10),
190         axis.text.y = element_text(size = 10),
191         axis.title.x = element_text(size = 10),
192         axis.title.y = element_text(size = 10)) + theme_bw()+
193   theme(legend.position = "bottom", legend.title=element_blank()) +
194   scale_fill_gradient(low="grey44", high="lightgrey")+
195   guides(fill = guide_colourbar(barwidth = 10))
196
197 p4 <- ggplot(data = importancia_2, aes(x = reorder(variable, MeanDecreaseGini),
198                                       y = MeanDecreaseGini,
199                                       fill = MeanDecreaseGini)) +
200   labs(x = "", title = element_blank(), y = "Mean Decrease Gini") + #x="Variable"
201   geom_col() + coord_flip() + theme_bw() +
202   theme(legend.position = "bottom", legend.title=element_blank()) +

```



## **ANEXO 4**

### **Script de muestreo espacial en GEE**

```

1 //#####
2 #####
3 //#                ESCUELA POLITÉCNICA
4 NACIONAL                #\\
5 //#                FACULTAD DE INGENIERÍA CIVIL Y
6 AMBIENTAL                #\\
7 //#                PIJ 17 -
8 05                #\\
9 //#####
10 #####
11
12 // CREATION DATE: //03/06/2020
13 // AUTHOR: DAVID CARCHIPULLA | cmorales.david@outlook.com
14 // Environmental Engineering Thesis
15 //LAST UPDATE: 08/07/2020
16
17 //##### Importing Shapefiles, DEM, and slope tiff
18 var AOI = ee.FeatureCollection("users/PIJ-17-05/wetland_bff_500m");
19 var drain = ee.FeatureCollection("users/PIJ-17-05/drain_bff10m");
20 var wells = ee.FeatureCollection('users/PIJ-17-05/wells_bff10m');
21 var roads = ee.FeatureCollection('users/PIJ-17-05/roads_w');
22 var dem = ee.Image("users/PIJ-17-05/dem_antisana");
23 var slp = ee.Image("users/PIJ-17-05/slp_antisana");
24 var hp = ee.FeatureCollection('users/PIJ-17-05/Humedal_Pugllohuma7');
25 var spatialClass = ee.FeatureCollection('users/PIJ-17-05/class_dissolve');
26
27 //##### Loading Sentinel-1 SAR collection and filter according to data
28 // collection type
29 var image = ee.ImageCollection('COPERNICUS/S1_GRD')
30   .filterBounds(AOI)
31   .filterDate('2014-01-01','2020-06-03')
32   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
33   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
34   .filterMetadata('resolution_meters', 'equals', 10);
35
36 // Filter speckle noise
37 var filterSpeckles = function(img) {
38   var vv = img.select('VV'); //select the VV polarization band
39   var vh = img.select('VH');
40   var vv_smoothed = vv.focal_median(30,'circle','meters'); //Apply a focal median
41   // filter
42   var vh_smoothed = vh.focal_median(30,'circle','meters'); //Apply a focal median
43   // filter
44   var smoothed = ee.Image.cat(vv_smoothed, vh_smoothed)
45     .rename(['VV S', 'VH S']);
46   return img.addBands(smoothed); // Add filtered VV band to original image
47 };
48 image=image.map(filterSpeckles);
49 print(image);
50
51 //##### Adding Polarimetric Indexes
52
53 // Function to compute and add polarization indexes as bands
54 // as well as, day of the year; slope; and elevation data
55 var addindexes = function(ima) {
56   var VV = ima.select('VV_S');
57   var VH = ima.select('VH_S');
58   var NDPI = VV.subtract(VH).divide(VV.add(VH));
59   var NVHI = VH.divide(VV.add(VH));
60   var NVVI = VV.divide(VV.add(VH));
61   var VhrVV = VH.divide(VV);
62
63   var doy = ima.date().getRelative('day', 'year');
64   var doyBand = ee.Image.constant(doy).uint16().rename('doy');
65
66   var recipe = ee.Image.cat(NDPI, NVHI, NVVI, VhrVV,doyBand,dem,slp)

```

```

61     .rename(['NDPI', 'NVHI', 'NVVI', 'VhrVV', 'DOY', 'DEM', 'slp']);
62     return ima.addBands(recipe);
63 };
64
65 // Add index bands to image collection
66 var image_2 = image.map(addindexes);
67
68 // set a date property to exactly 00:00 AM
69 // Also, S1 images were clipped by the AOI
70 var image_2 = image_2.map(function(image){
71     return image.set('simpleTime', ee.Date(image.date()
72         .format('YYYY-MM-dd')).millis()).clip(AOI);
73 });
74
75 print(image_2);
76
77 /////////////// Making a spatial classification
78
79 ///Importing classified dates
80 var F0Date = ee.List(['2015-10-11', '2015-10-13', '2015-10-14', '2015-10-15',
81     '2015-10-18', '2015-11-01', '2015-11-04', '2015-11-05',
82     '2015-11-06', '2015-11-07', '2015-11-17', '2015-11-23',
83     '2015-11-24', '2015-11-25', '2015-12-15', '2016-04-18',
84     '2016-04-24', '2016-04-28', '2016-04-29', '2016-04-30',
85     '2016-05-01', '2016-05-04', '2016-05-05', '2016-05-06',
86     '2016-05-07', '2016-05-08', '2016-05-09', '2016-05-10',
87     '2016-05-11', '2016-05-12', '2016-05-13', '2016-05-14',
88     '2016-05-15', '2016-05-16', '2016-05-17', '2016-05-18',
89     '2016-05-28', '2016-05-29', '2016-05-30', '2016-06-01',
90     '2016-06-02', '2016-06-03', '2016-06-04', '2016-06-05',
91     '2016-06-06', '2016-06-07', '2018-03-01', '2018-03-02',
92     '2018-03-03', '2018-03-04', '2018-03-05', '2018-03-06',
93     '2018-03-07', '2018-04-11', '2018-04-14', '2018-04-15',
94     '2018-04-16', '2018-04-17', '2018-04-18', '2018-04-19',
95     '2018-04-20', '2018-04-21', '2018-04-22', '2018-04-23',
96     '2018-04-24', '2018-04-25', '2018-04-27', '2018-04-28',
97     '2018-04-29', '2018-04-30', '2018-05-01', '2018-05-02',
98     '2018-05-03', '2018-05-04', '2018-05-05', '2018-05-06',
99     '2018-05-07', '2018-05-08', '2018-05-09', '2018-05-10',
100    '2018-05-11', '2018-05-12', '2018-05-13', '2018-05-14',
101    '2018-05-15', '2018-05-16', '2018-05-17', '2018-05-18',
102    '2018-05-19', '2018-05-20', '2018-05-21', '2018-05-22',
103    '2018-05-23', '2018-05-24', '2018-05-25', '2018-05-26',
104    '2018-05-27', '2018-05-28', '2018-05-29', '2018-05-30',
105    '2018-05-31', '2018-06-01', '2018-06-02', '2018-06-03',
106    '2018-06-04', '2018-06-05', '2018-06-19', '2018-06-20',
107    '2018-06-21', '2018-06-22', '2018-06-23', '2018-06-24',
108    '2018-06-25', '2018-06-26', '2018-06-27', '2018-06-28',
109    '2018-06-29', '2018-07-01', '2018-07-03', '2018-07-04',
110    '2018-07-05', '2018-07-06', '2018-07-07', '2018-07-08',
111    '2018-07-09', '2018-07-10', '2018-07-11', '2018-07-12',
112    '2018-07-18', '2018-07-22', '2018-07-23', '2018-07-27',
113    '2018-07-28', '2018-07-30', '2018-07-31', '2018-08-01',
114    '2018-08-02', '2018-08-03', '2018-08-04', '2018-08-05',
115    '2018-08-06', '2018-08-07', '2018-08-08', '2018-08-09',
116    '2018-08-12', '2018-08-13', '2018-08-14', '2018-08-16',
117    '2018-09-04', '2018-09-05', '2018-09-08', '2018-09-09',
118    '2018-09-11', '2018-09-14', '2018-09-15', '2018-09-16',
119    '2018-09-17', '2018-10-03', '2018-10-04', '2018-10-05',
120    '2018-10-06', '2018-10-07', '2018-10-08', '2018-10-09',
121    '2018-10-10', '2018-10-11', '2018-10-13', '2018-10-20',
122    '2018-10-26', '2018-10-27', '2018-10-29', '2018-11-03',
123    '2018-11-04', '2018-11-05', '2018-11-06', '2018-11-11',
124    '2018-11-15', '2018-11-18', '2018-11-20', '2018-11-21',
125    '2018-11-22', '2018-11-26', '2018-11-27', '2018-11-30',
126    '2018-12-01', '2018-12-02', '2018-12-03', '2018-12-04',
127    '2018-12-05', '2018-12-06', '2018-12-07', '2018-12-08',
128    '2018-12-09', '2018-12-11', '2018-12-12', '2018-12-13',

```

```

129         '2018-12-14', '2018-12-15', '2018-12-19', '2018-12-20'])
130     .map(function(date) {return ee.Date(date).millis();});
131
132     var FlDate = ee.List(['2015-10-05', '2015-10-06', '2015-10-07', '2015-10-08',
133         '2015-10-09', '2015-10-10', '2015-10-21', '2015-10-22',
134         '2015-10-23', '2015-10-24', '2015-10-26', '2015-10-27',
135         '2015-10-28', '2015-10-30', '2015-11-02', '2015-11-08',
136         '2015-11-09', '2015-11-10', '2015-11-11', '2015-11-12',
137         '2015-11-13', '2015-11-14', '2015-11-15', '2015-11-16',
138         '2015-11-18', '2015-11-19', '2015-11-20', '2015-11-21',
139         '2015-11-22', '2015-11-26', '2015-11-27', '2015-11-29',
140         '2015-11-30', '2015-12-01', '2015-12-02', '2015-12-06',
141         '2015-12-07', '2015-12-08', '2015-12-09', '2015-12-10',
142         '2015-12-11', '2015-12-12', '2015-12-16', '2015-12-17',
143         '2015-12-18', '2015-12-21', '2015-12-22', '2015-12-23',
144         '2015-12-25', '2015-12-26', '2015-12-27', '2015-12-28',
145         '2015-12-30', '2015-12-31', '2016-01-01', '2016-01-02',
146         '2016-01-03', '2016-01-04', '2016-01-05', '2016-01-06',
147         '2016-01-07', '2016-01-08', '2016-01-09', '2016-01-10',
148         '2016-01-11', '2016-01-12', '2016-01-13', '2016-01-14',
149         '2016-01-16', '2016-01-17', '2016-01-20', '2016-01-21',
150         '2016-01-22', '2016-01-23', '2016-01-24', '2016-01-25',
151         '2016-01-29', '2016-01-30', '2016-01-31', '2016-02-03',
152         '2016-02-06', '2016-02-07', '2016-02-08', '2016-02-09',
153         '2016-02-10', '2016-02-11', '2016-02-12', '2016-02-13',
154         '2016-02-14', '2016-02-16', '2016-02-17', '2016-02-18',
155         '2016-02-19', '2016-02-20', '2016-02-21', '2016-02-22',
156         '2016-02-23', '2016-02-24', '2016-02-25', '2016-02-26',
157         '2016-02-27', '2016-02-28', '2016-02-29', '2016-03-01',
158         '2016-03-02', '2016-03-03', '2016-03-05', '2016-03-06',
159         '2016-03-07', '2016-03-08', '2016-03-09', '2016-03-10',
160         '2016-03-11', '2016-03-12', '2016-03-13', '2016-03-14',
161         '2016-03-15', '2016-03-16', '2016-03-17', '2016-03-18',
162         '2016-03-19', '2016-03-20', '2016-03-21', '2016-03-22',
163         '2016-03-23', '2016-03-24', '2016-03-25', '2016-03-26',
164         '2016-03-28', '2016-03-29', '2016-03-31', '2016-04-01',
165         '2016-04-02', '2016-04-03', '2016-04-04', '2016-04-05',
166         '2016-04-06', '2016-04-08', '2016-04-09', '2016-04-10',
167         '2016-04-11', '2016-04-12', '2016-04-14', '2018-03-08',
168         '2018-03-09', '2018-03-10', '2018-03-11', '2018-03-12',
169         '2018-04-10', '2018-04-26', '2018-07-17', '2018-07-19',
170         '2018-07-20', '2018-07-21', '2018-07-26', '2018-07-29',
171         '2018-08-18', '2018-08-19', '2018-08-20', '2018-08-22',
172         '2018-08-25', '2018-08-26', '2018-08-27', '2018-08-28',
173         '2018-08-29', '2018-08-30', '2018-08-31', '2018-09-01',
174         '2018-09-02', '2018-09-03', '2018-09-12', '2018-09-13',
175         '2018-09-18', '2018-09-19', '2018-09-20', '2018-09-21',
176         '2018-09-23', '2018-09-24', '2018-09-25', '2018-09-26',
177         '2018-09-27', '2018-09-29', '2018-09-30', '2018-10-15',
178         '2018-10-16', '2018-10-17', '2018-10-18', '2018-10-19',
179         '2018-10-21', '2018-10-31', '2018-11-02', '2018-11-08',
180         '2018-11-09', '2018-11-12', '2018-11-13', '2018-11-24',
181         '2018-11-28', '2018-11-29', '2018-12-10', '2018-12-16',
182         '2018-12-17', '2018-12-18', '2018-12-22', '2018-12-23',
183         '2018-12-24', '2018-12-28', '2018-12-29', '2018-12-30',
184         '2018-12-31', '2019-01-01', '2019-01-02', '2019-01-03',
185         '2019-01-04', '2019-01-05', '2019-01-06', '2019-01-07',
186         '2019-01-08', '2019-01-09', '2019-01-10', '2019-01-11',
187         '2019-01-12', '2019-01-13', '2019-01-14', '2019-01-15',
188         '2019-01-16', '2019-01-17', '2019-01-18', '2019-01-19',
189         '2019-01-20', '2019-01-21', '2019-01-22', '2019-01-23',
190         '2019-01-24', '2019-01-25', '2019-01-26', '2019-01-27',
191         '2019-01-28', '2019-01-29', '2019-01-30', '2019-01-31',
192         '2019-02-01', '2019-02-02', '2019-02-03', '2019-02-04',
193         '2019-02-05', '2019-02-06', '2019-02-07', '2019-02-08',
194         '2019-02-09', '2019-02-10', '2019-02-11', '2019-02-12',
195         '2019-02-13', '2019-02-14', '2019-02-15', '2019-02-16',
196         '2019-02-18', '2019-02-19', '2019-02-20', '2019-02-21',

```



```

197 '2019-02-22', '2019-02-23', '2019-02-24', '2019-02-25',
198 '2019-02-26', '2019-02-27', '2019-02-28', '2019-03-01',
199 '2019-03-02', '2019-03-03', '2019-03-04', '2019-03-05',
200 '2019-03-06', '2019-03-07', '2019-03-08', '2019-03-09',
201 '2019-03-10', '2019-03-11', '2019-03-12', '2019-03-13',
202 '2019-03-14', '2019-03-15', '2019-03-16', '2019-03-17',
203 '2019-03-18', '2019-03-19', '2019-03-20', '2019-03-21',
204 '2019-03-22', '2019-03-23', '2019-03-24', '2019-03-25',
205 '2019-03-26', '2019-03-27', '2019-03-28', '2019-03-29',
206 '2019-03-30', '2019-03-31', '2019-04-01', '2019-04-02',
207 '2019-04-03', '2019-04-04', '2019-04-05', '2019-04-06',
208 '2019-04-07', '2019-04-09', '2019-04-10', '2019-04-11',
209 '2019-04-12', '2019-04-13', '2019-04-14', '2019-04-15',
210 '2019-04-16', '2019-04-17', '2019-04-18', '2019-04-19',
211 '2019-04-20', '2019-04-21', '2019-04-22', '2019-04-23',
212 '2019-04-24', '2019-04-25', '2019-04-26', '2019-04-28',
213 '2019-04-29', '2019-04-30', '2019-05-01', '2019-05-02',
214 '2019-05-03', '2019-05-04', '2019-05-05', '2019-05-06',
215 '2019-05-07', '2019-06-27', '2019-06-28', '2019-06-29',
216 '2019-06-30', '2019-07-01', '2019-07-02', '2019-07-03',
217 '2019-07-04', '2019-07-05', '2019-07-06', '2019-07-07',
218 '2019-07-08', '2019-07-10', '2019-07-11', '2019-07-12',
219 '2019-07-13', '2019-07-14', '2019-07-15', '2019-07-16',
220 '2019-07-17', '2019-07-18', '2019-07-19', '2019-07-20',
221 '2019-07-21', '2019-07-22', '2019-07-23', '2019-07-24',
222 '2019-07-25', '2019-07-26', '2019-07-27', '2019-07-28',
223 '2019-07-29', '2019-07-30', '2019-07-31', '2019-08-01',
224 '2019-08-02', '2019-08-03', '2019-08-04', '2019-08-05',
225 '2019-08-06', '2019-08-07', '2019-08-08', '2019-08-09',
226 '2019-08-10', '2019-08-11', '2019-08-12', '2019-08-17',
227 '2019-08-18', '2019-08-19', '2019-08-20', '2019-08-22',
228 '2019-08-23', '2019-08-24', '2019-08-25', '2019-08-26',
229 '2019-08-27', '2019-08-29', '2019-08-30', '2019-08-31',
230 '2019-09-01', '2019-09-02', '2019-09-03', '2019-09-04',
231 '2019-09-05', '2019-09-06', '2019-09-07', '2019-09-08',
232 '2019-09-09', '2019-09-10', '2019-09-11', '2019-09-12',
233 '2019-09-13', '2019-09-14', '2019-09-15', '2019-09-16',
234 '2019-09-17', '2019-09-18', '2019-09-19', '2019-09-21',
235 '2019-09-22', '2019-09-23', '2019-09-24', '2019-09-25',
236 '2019-09-26', '2019-09-27', '2019-09-28', '2019-09-29',
237 '2019-10-01', '2019-10-02', '2019-10-03', '2019-10-04',
238 '2019-10-05', '2019-10-06', '2019-10-07', '2019-10-08',
239 '2019-10-09', '2019-10-10', '2019-10-11', '2019-10-12',
240 '2019-10-13', '2019-10-14', '2019-10-15', '2019-10-16',
241 '2019-10-17', '2019-10-18', '2019-10-19', '2019-10-20',
242 '2019-10-21', '2019-10-22', '2019-10-24', '2019-10-25',
243 '2019-10-26', '2019-10-27', '2019-10-28', '2019-10-29',
244 '2019-10-30', '2019-10-31', '2019-11-02', '2019-11-03',
245 '2019-11-04', '2019-11-05', '2019-11-06', '2019-11-07',
246 '2019-11-08', '2019-11-10', '2019-11-13', '2019-11-14',
247 '2019-11-15', '2019-11-16', '2019-11-17', '2019-11-18',
248 '2019-11-19', '2019-11-20', '2019-11-22', '2019-11-23',
249 '2019-11-24', '2019-11-25', '2019-11-29', '2019-11-30',
250 '2019-12-01', '2019-12-02', '2019-12-03', '2019-12-04',
251 '2019-12-06', '2019-12-08', '2019-12-09', '2019-12-10',
252 '2019-12-11', '2019-12-13', '2019-12-14', '2019-12-15',
253 '2019-12-17', '2019-12-18', '2019-12-22', '2019-12-26'])
254 .map(function(date){return ee.Date(date).millis()});
255
256 //Applying date filter
257 var Class0Images = image_2.filter(ee.Filter.inList("simpleTime", F0Date));
258 print(Class0Images); // Saturation Dates
259
260 var Class1Images = image_2.filter(ee.Filter.inList("simpleTime", F1Date));
261 print(Class1Images); // Drought Dates
262
263 // There are 3 spatial classes in this study:
264 // 10: saturated soil which is marked off by draining area

```

```

265 // 11: wet soil which is marked off by wells locations
266 // 12: dry soil which is marked of by road area
267 // the First class is imported from Class0Images,
268 // the Second class is imported from Class0Images; and
269 // the Third class is imported from Class1Images;
270
271 // To train the random forest model, it is needed to sample images
272 // However, It is an ImageCollection and the result of sample it is multiple
273 // sample from each one.
274 // It is needed to merge them all in a single sample
275
276 // Images' bands will be added to the first image
277 var Class0Merged = Class0Images.toBands();
278 var Class1Merged = Class1Images.toBands();
279
280 // This single image is sampled, and added a landcover properties
281 // Landcover is used as a classification propertie, as mentioned before
282 var WSsample = Class0Merged.sampleRegions({ //Wet season has three classes
283   collection: spatialClass, //Wet soil Vegetation is sampled by well area
284   properties: ['landcover'], //Saturated soil is sampled by drainage area
285   scale: 10 }); //Dry soil is sampled by drainage area
286 print(WSsample);
287
288 var FV = Class1Merged.sampleRegions({ //Dry season has two classes
289   collection: wells,
290   properties: ['landcover'], //Flooded Vegetation is sampled by well area
291   scale: 10 });
292 print(FV);
293
294 var soil = Class1Merged.sampleRegions({ //Dry season has two classes
295   collection: roads,
296   properties: ['landcover'], //Soil is sampled by road area
297   scale: 10 });
298 print(soil);
299
300 // Then, these new feature collections are exported to R
301 // There, Data will be reshaped and studied
302 // Resulting in a number of decision trees and importance of variables
303
304 Export.table.toDrive({
305   collection: WSsample,
306   description: 'WetSeasonSample',
307   fileFormat: 'CSV'
308 });
309
310 Export.table.toDrive({
311   collection: FV,
312   description: 'FVSample',
313   fileFormat: 'CSV'
314 });
315
316 Export.table.toDrive({
317   collection: soil,
318   description: 'SoilSample',
319   fileFormat: 'CSV'
320 });
321
322 /////////////// Loading Sentinel-2 collection and to filter according to data
collection type
323
324 /**
325  * Function to mask clouds using the Sentinel-2 QA band
326  * @param {ee.Image} image Sentinel-2 image
327  * @return {ee.Image} cloud masked Sentinel-2 image
328  */
329 function maskS2clouds(image) {
330   var QA = image.select('QA60');
331

```

```

332 // Bits 10 and 11 are clouds and cirrus, respectively.
333 var cirrus = QA.bitwiseAnd(Math.pow(2, 11)).eq(0);
334 var cloud = QA.bitwiseAnd(Math.pow(2, 10)).eq(0);
335
336 return image.updateMask(cirrus).updateMask(cloud);
337 }
338
339 //Load Sentinel-2 collection and filter according to data collection type
340 var s2 = ee.ImageCollection('COPERNICUS/S2')
341   .filterBounds(hp)
342   .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less than',60)
343   .map(maskS2clouds);
344
345 // Function to compute and add NDVI, as well as, NDWI
346 var addS2indexes = function(ima) {
347   var NIR = ima.select('B8');
348   var RED = ima.select('B4');
349   var NDVI=ima.normalizedDifference(['B8', 'B4']);
350   var NDWI=ima.normalizedDifference(['B8', 'B11']);
351   var MNDWI=ima.normalizedDifference(['B3', 'B11']);
352   var WDRI =NIR.multiply(0.05).subtract(RED).divide(NIR.multiply(0.05).add(RED));
353   var EVI2 =NIR.subtract(RED).multiply(2.5).divide(NIR.add(2.4).multiply(RED.add(1)));
354   var RE = NIR.divide(ima.select('B5').subtract(1));
355   var indexes= ee.Image.cat(NDVI, NDWI,MNDWI,WDRI,EVI2,RE)
356     .rename(['NDVI','NDWI','MNDWI','WDRI','EVI2','RE']);
357   return ima.addBands(indexes);
358 };
359
360 // Add index bands to image collection
361 s2 = s2.map(addS2indexes);
362
363 // set a date property to exactly 00:00 AM
364 // Also, S1 images were clipped by the AOI
365 s2 = s2.map(function(image) {
366   return image.set('simpleTime', ee.Date(image.date()
367     .format('YYYY-MM-dd')).millis()).clip(AOI);
368 });
369
370
371 //////////////// Filtering by assessing dates
372 var s2Dates = ee.List(['2017-06-06','2017-07-16','2017-08-20','2017-09-19',
373   '2017-10-19','2017-12-18','2018-01-07','2018-07-16',
374   '2018-08-25','2018-10-24','2018-12-23','2019-02-16'])
375   .map(function(date){return ee.Date(date).millis()});
376
377 //Applying date filter
378 s2 = s2.filter(ee.Filter.inList("simpleTime", s2Dates));
379 print(s2); // Saturation Dates
380
381 // To train the unsupervised classification model, it is needed to sample images
382 // However, It is an ImageCollection and the result of sample it is multiple
383 // sample from each one.
384 // It is needed to merge them all in a single sample
385
386 // Images' bands will be added to the first image
387 var S2Merged = s2.toBands();
388
389 // This single image is sampled
390 //The sample will collect soil, saturated soil and wet soil information
391 var S2Sample = S2Merged.sample({
392   region: spatialClass,
393   scale: 10
394 });
395 print(S2Sample);
396
397 // Then, these new feature collection is exported to R
398 // There, Data will be reshaped
399 // in order to use data in clustering
400
401 Export.table.toDrive({
402   collection: S2Sample,
403   description:'S2Sample',
404   fileFormat: 'CSV'
405 });
406

```

## **ANEXO 5**

**Script de muestreo espacial en R Studio**



```

1 ##### PIJ 17-05 #####
2 ##### INDEXES #####
3 ##### EPN #####
4 ##### David Carchipulla 11/06/2020 #####
5
6
7 ##### System Requisistes #####
8 ##To clear environment and RAM
9 rm(list=ls()); gc()
10
11 ##To set Environment Variables - Time Zone
12 Sys.setenv(tz="UTC")
13
14 ###To install and to call packages
15 packages<-c('dplyr','readr','gtools','tm','ggplot2',
16            'ggpubr','randomForest','corrplot',
17            'ggcorrplot','tibble','data.table',
18            'ranger','tidyr','caret',
19            'party','partykit')
20
21 ipak <- function(pkg) {
22   new.pkg <- pkg[!(pkg %in% installed.packages()[, "Package"])]
23   if (length(new.pkg))
24     install.packages(new.pkg, dependencies = TRUE)
25   sapply(pkg, require, character.only = TRUE)
26 }
27
28 ipak(packages)
29
30 # Importing data -----
31 ## Getting files' names
32 files <- list.files(path = './data',
33                    full.names = FALSE,
34                    pattern = ".csv") %>% mixedsort()
35 nom <- paste0(files)
36 nom <- removeWords(nom, words = ".csv")
37 nom
38
39 # Opening each csv after knowing their names and adding S_ to their names
40 for (i in 1:length(nom)){
41   assign(paste('S',nom[i],sep=" "),data.frame(read.csv(file =
42     paste('./data', '/', nom[i], '.csv', sep=' '), ", ",
43           na.strings = c("", "NA"), header = T,
44           dec = ".")))
45 }
46
47 # Merging samples -----
48 sample<-data.frame(DEM=NA, DOY=NA, NDPI=NA, NVHI=NA, NVVI=NA,
49                   VH=NA, VH_S=NA, VhrVV=NA, VV=NA, VV_S=NA,
50                   angle=NA, slp=NA, landcover=NA, .geo=NA)
51
52 ##### Reshaping Flooded Vegetation Sample
53 names<-colnames(sample[1:12])
54 m<-S_FVSample[2:13]
55 n<-S_FVSample[14:25]
56 colnames(m)<-names
57 colnames(n)<-names
58 FV<-rbind(m, n)
59
60 for (col in seq(26,1021,by=12)) {
61   l<-S_FVSample[col:(col+11)]
62   colnames(l)<-names
63   FV<-rbind(FV, l)
64 }
65
66 FV<-FV%>%
67   select(-c(6,9))%>%
68   mutate(landcover=11, .geo=NA)

```

```

67
68
69 ##### Reshaping soil Sample
70 m<-S_SoilSample[2:13]
71 n<-S_SoilSample[14:25]
72 colnames(m)<-names
73 colnames(n)<-names
74 soil<-rbind(m,n)
75
76 for (col in seq(26,1021,by=12)) {
77   l<-S_SoilSample[col:(col+11)]
78   colnames(l)<-names
79   soil<-rbind(soil,l)
80 }
81
82 soil<-soil%>%
83   select(-c(6,9))%>%
84   mutate(landcover=12,.geo=NA)
85
86 ##### Reshaping water Sample
87 m<-S_WetSeasonSample[2:13]
88 n<-S_WetSeasonSample[14:25]
89 colnames(m)<-names
90 colnames(n)<-names
91 water<-rbind(m,n)
92
93 for (col in seq(26,277,by=12)) {
94   l<-S_WetSeasonSample[col:(col+11)]
95   colnames(l)<-names
96   water<-rbind(water,l)
97 }
98 WSlandcover<-S_WetSeasonSample[[326]]
99 water<-water%>%
100   select(-c(6,9))%>%
101   mutate(landcover=rep len(WSlandcover,length.out = 23989)
102     ,.geo=NA)
103
104 ### Merging all samples
105
106 sample<-rbind(FV,soil,water)
107
108 write.csv(sample,'Msample.csv',na='')
109 ### Add system:index as colname for rownames
110
111 # Plotting angle variation -----
112 hist(sample$angle)
113
114 ggplot(sample, aes(x=DOY,y=angle, color=as.factor(landcover))) +
115   geom_point(size=3.8) + scale_color_hue(h = c(90,180),l=80, c=70) +
116   labs(color = "Clase",x='Día del año',y='Ángulo de captura °') +
117   theme_bw() +
118   theme(legend.title=element_text(size=30),
119         legend.text=element_text(size=28),
120         text = element_text(size=30), panel.grid.major = element_blank(),
121         panel.grid.minor = element_blank()+border()+
122         guides(colour = guide_legend(ncol = 2))
123
124 ### Angle shall be a variable
125 ### It is not a constant
126
127
128 ##### CONSTRUCTION 1 #####
129 ###UPLOADING TRAIN DATA AND SAMPLE
130 rfData<-sample[,1:11]
131 ### CLASS SHALL BE A FACTOR
132 rfData$landcover<-as.factor(rfData$landcover)
133
134 ## VARIABLES' CORRELATION

```



## **ANEXO 6**

### **Script de clasificación espacial**

```

1  #####
2  #####
3  //#          ESCUELA POLITÉCNICA          #\\
4  NACIONAL
5  //#          FACULTAD DE INGENIERÍA CIVIL Y          #\\
6  AMBIENTAL
7  //#          PIJ 17 -          #\\
8  05
9  #####
10 #####
11
12 // CREATION DATE: 05/01/2019
13 // AUTHOR: DAVID CARCHIPULLA | cmorales.david@outlook.com
14 // Environmental Engineering Thesis
15 //LAST UPDATE: 30/06/2020
16
17 #####
18 ##### DEFINE UI COMPONENTS #####
19 #####
20
21 // SET UP PRIMARY PANELS
22 // control panel
23 var controlPanel = ui.Panel({
24   layout: ui.Panel.Layout.flow('vertical'),
25   style: {width: '340px'}
26 });
27
28 // plot panel
29 var plotsPanelLabel = ui.Label('LandTrendr Time Series Plots', {fontWeight: 'bold',
30   stretch: 'horizontal'});
31 var plotPanel = ui.Panel(null, null, {stretch: 'horizontal'});
32 var plotPanelParent = ui.Panel([plotsPanelLabel, plotPanel], null, {width: '480px'});
33
34 // map panel
35 var map = ui.Map();
36 map.setOptions('HYBRID');
37 var processingLabel = ui.Label('Processing, please wait...', {shown:false, position:
38   'top-center'});
39 map.add(processingLabel);
40
41 // params panel
42 var runParams = [
43   {label: 'Number of wet season images:', value: 23},
44   {label: 'Number of drought season images:', value: 85},
45   {label: 'Wet season sampling areas:', value: 'Drainage, roads, and wells'},
46   {label: 'Drought season sampling areas:', value: 'Roads, and wells'},
47   {label: 'Speckle filter:', value: 'Focal median ≈ 30 meters'},
48   {label: 'Supervised Classification variables:', value:'Angle, day of the year,
49     DEM, slope, VH, and VV '},
50   {label: 'Number of decision trees:', value: 100},
51 ];
52
53 var paramBoxes = [];
54 var paramPanels = [ui.Label('Parameters',{fontWeight: 'bold'})];
55 runParams.forEach(function(param, index){
56   var paramLabel = ui.Label(param.label,{fontWeight: 'bold'});
57   var paramBox = ui.Label({value:param.value});
58   paramBox.style().set('stretch', 'horizontal');
59   var paramPanel = ui.Panel([paramLabel,paramBox],
60     ui.Panel.Layout.Flow('horizontal'));
61   paramBoxes.push(paramBox);
62   paramPanels.push(paramPanel);
63 });
64 var paramPanel = ui.Panel(paramPanels,null,{stretch: 'horizontal'});

```

```

60 //////////////// Importing Shapefiles
61 var AOI = ee.FeatureCollection("users/PIJ-17-05/wetland_bff_500m"); //AVAILABLE SHAPES
62 var drain = ee.FeatureCollection("users/PIJ-17-05/drain_bff10m"); //AVAILABLE SHAPES
63 var wells = ee.FeatureCollection("users/PIJ-17-05/wells_bff10m");
64 var roads = ee.FeatureCollection("users/PIJ-17-05/roads_w");//AVAILABLE SHAPES
65 var dem = ee.Image("users/PIJ-17-05/dem_antisana");//AVAILABLE TIFF
66 var slp = ee.Image("users/PIJ-17-05/slp_antisana");
67 var hp = ee.FeatureCollection("users/PIJ-17-05/Humedal_Pugllohuma7");
68 var aguas_abiertas = ee.FeatureCollection("users/PIJ-17-05/aguas_abiertas");
69
70 //////////////// Load Sentinel-1 SAR collection
71 //and filter according to data collection type
72 var image = ee.ImageCollection('COPERNICUS/S1_GRD')
73   .filterBounds(AOI)
74   .filterDate('2017-01-01','2019-12-31')
75   .filter(ee.Filter.listContains('transmitterReceiverPolarisation','VV'))
76   .filter(ee.Filter.listContains('transmitterReceiverPolarisation','VH'))
77   .filterMetadata('resolution_meters','equals',10);
78
79 // Filter speckle noise
80 var filterSpeckles = function(img) {
81   var vv = img.select('VV');//select the VV polarization band
82   var vh = img.select('VH');
83   var vv_smoothed = vv.focal_median(30,'circle','meters');//Apply a focal median
      filter
84   var vh_smoothed = vh.focal_median(30,'circle','meters');//Apply a focal median
      filter
85   var smoothed = ee.Image.cat(vv_smoothed, vh_smoothed)
86     .rename(['VV_S','VH_S']);
87   return img.addBands(smoothed);// Add filtered VV band to original image
88 };
89 image=image.map(filterSpeckles);
90 print(image);
91
92 //////////////// Adding Polarimetric Indexes
93
94 // Function to compute and add day of the year; slope; and elevation data
95 // Also, Images are being clipped
96 var addindexes = function(ima) {
97   var doy = ima.date().getRelative('day','year');
98   var doyBand = ee.Image.constant(doy).uint16().rename('doy');
99
100   var recipe = ee.Image.cat(doyBand,dem,slp)
101     .rename(['DOY','DEM','slp']);
102   return ima.addBands(recipe).clip(AOI);
103 };
104
105 // Add index bands to image collection
106 var image_2 = image.map(addindexes);
107
108 // Reshaped sample is imported to GEE
109 var ClassSample = ee.FeatureCollection("users/PIJ-17-05/ClassSample");
110
111 // Needed variables are established
112 var bands = ['DEM','DOY','VH_S','VV_S','angle','slp'];
113
114 // Classifier is trained
115 // 800 decision trees are needed
116 var classifier = ee.Classifier.randomForest(100).train({
117   features: ClassSample,
118   classProperty: 'landcover',
119   inputProperties: bands // Not all variables are needed,
120   }); // Just those included in bands
121
122 print(classifier);
123
124 // Classification is implemented in image_2
125 // image_2 includes all images provided by GEE

```



```

126 // and it already has computed polarimetric indexes
127
128 var rfModel = function(classifying) {
129     var classified = classifying.select(bands).classify(classifier);
130     return classifying.addBands(classified);
131 };
132 var classifiedD = image_2.map(rfModel);
133 print(classifiedD);
134
135 // Classes are selected and added to the image as new bands
136 // It is needed to visualize spatial classification
137 var add_class = function(img) {
138     var class_band = img.select('classification');
139     var ss = class_band.eq(10); //Identify classified pixels
140     var ws = class_band.eq(11); // and set them equal to 1.
141     var ds = class_band.eq(12); // All other pixels set to 0
142     ss = ss.updateMask(ss); //Remove all pixels equal to 0
143     ws = ws.updateMask(ws); //Remove all pixels equal to 0
144     ds = ds.updateMask(ds); //Remove all pixels equal to 0
145     var class_bands = ee.Image.cat(ss, ws, ds)
146         .rename(['Saturated', 'Wet', 'Dry']);
147     return img.addBands(class_bands);
148 };
149
150 //Map classification across sentinel-1 collection and print to console to inspect
151 classifiedD = classifiedD.map(add_class);
152
153 //Load Sentinel-2 image collection,
154 //filter according to data collection type, and apply cloud mask
155 /**
156  * Function to mask clouds using the Sentinel-2 QA band
157  * @param {ee.Image} image Sentinel-2 image
158  * @return {ee.Image} cloud masked Sentinel-2 image
159  */
160 function maskS2clouds(image) {
161     var QA = image.select('QA60');
162
163     // Bits 10 and 11 are clouds and cirrus, respectively.
164     var clouds = QA.bitwiseAnd(Math.pow(2, 10)).eq(0);
165     var cirrus = QA.bitwiseAnd(Math.pow(2, 11)).eq(0);
166
167     return image.updateMask(clouds).updateMask(cirrus);
168 }
169
170 //Load Sentinel-2 collection and filter according to data collection type
171 var s2 = ee.ImageCollection('COPERNICUS/S2')
172     .filterBounds(hp)
173     .filterDate('2017-01-01', '2019-12-31')
174     .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less_than', 20)
175     .map(maskS2clouds);
176
177 // Function to compute and add NDVI, as well as, NDWI
178 var MSindexes = function(ima) {
179     var NDVI=ima.normalizedDifference(['B8', 'B4']);
180     var NDWI=ima.normalizedDifference(['B8', 'B11']);
181     var indexes= ee.Image.cat(NDVI, NDWI)
182         .rename(['NDVI', 'NDWI']);
183     return ima.addBands(indexes.clip(AOI));
184 };
185
186 // Add index bands to image collection
187 s2 = s2.map(MSindexes);
188 print(s2);
189
190 //Make time series of pixels within region
191 var Class_11_Chart = ui.Chart.image.series({
192     imageCollection: classifiedD.select('Wet'),
193     region: AOI,

```

```
194     reducer: ee.Reducer.sum(),
195     scale:100
196   })
197   .setOptions({
198     title: 'Wet soil pixels',
199     hAxis: {'title': 'Date'},
200     vAxis: {'title': 'Ha of wet soil'},
201     lineWidth: 2,
202     series: {
203       0: {color: '#70dcbe'} // wet soil
204     }
205   });
206
207 //Set the position of the chart and add it to the map
208 Class_11_Chart.style().set({
209   position: 'bottom-center',
210   width: '500px',
211   height: '300px'
212 });
213
214 var Class_10_Chart = ui.Chart.image.series({
215   imageCollection: classifiedD.select('Saturated'),
216   region: AOI,
217   reducer: ee.Reducer.sum(),
218   scale:100
219 })
220 .setOptions({
221   title: 'Saturated soil pixels',
222   hAxis: {'title': 'Date'},
223   vAxis: {'title': 'Ha of saturated soil'},
224   lineWidth: 2,
225   series: {
226     0: {color: '#2007ab'} // saturated soil
227   }
228 });
229
230 //Set the position of the chart and add it to the map
231 Class_10_Chart.style().set({
232   position: 'bottom-left',
233   width: '500px',
234   height: '300px'
235 });
236
237
238 var Class_12_Chart = ui.Chart.image.series({
239   imageCollection: classifiedD.select('Dry'),
240   region: AOI,
241   reducer: ee.Reducer.sum(),
242   scale:100
243 })
244 .setOptions({
245   title: 'Dry soil pixels',
246   hAxis: {'title': 'Date'},
247   vAxis: {'title': 'Ha of dry soil'},
248   lineWidth: 2,
249   series: {
250     0: {color: '#38ad1b'} // dry soil
251   }
252 });
253
254 //Set the position of the chart and add it to the map
255 Class_12_Chart.style().set({
256   position: 'bottom-right',
257   width: '500px',
258   height: '300px'
259 });
260
261
```



```

262 // Create a label on the map.
263 var label = ui.Label({
264   value: 'Click a point on the chart to show the image for that date.',
265   style: {position: 'bottom-center'}
266 });
267 map.add(label);
268
269 //Create callback function that adds image to the map coresponding with clicked data
point on chart
270 Class_11_Chart.onClick(function(xValue, yValue, seriesName) {
271   if (!xValue) return; // Selection was cleared.
272
273   // Show the image for the clicked date.
274   var equalDate = ee.Filter.equals('system:time_start', xValue);
275   //Find image coresponding with clicked data
276   var rfClass = ee.Image(classifiedD.filter(equalDate)
277     .first()).select('classification');
278   var ic = s2.map(function(image){
279     return image.set(
280       'dateDist',
281       ee.Number(image.get('system:time_start')).subtract(rfClass
282         .get('system:time_start')).abs()
283     );
284   });
285   ic = ic.sort('dateDist');
286   var S2NDVI = ee.Image(ic.first()).select('NDVI');
287   var S2NDWI = ee.Image(ic.first()).select('NDWI');
288   //Make map layer based on SAR image, reset the map layers,
289   // and add this new layer
290   var S1Layer = ui.Map.Layer(rfClass, {
291     max: 12,
292     min: 10,
293     palette: ['#2007ab', '#70dcbe', '#38ad1b']
294   }, 'SAR Classification');
295   map.layers().reset([S1Layer]);
296   var waterPalette = ['red', 'yellow', 'green', 'blue'];
297   map.addLayer(S2NDWI, {min: -1, max: 1, palette: waterPalette},
298     'NDWI');
299   var vegetationPalette = ['blue', 'white', 'green'];
300   map.addLayer(S2NDVI, {min: -1, max: 1, palette: vegetationPalette},
301     'NDVI');
302   // Show a label with the date on the map.
303   label.setValue(new Date(xValue)).toUTCString();
304
305
306 //Map aguas_abiertas
307 //map.addLayer(aguas_abiertas, {color: 'white'} , 'Aguas abiertas');
308 map.addLayer(hp, {}, 'Humedal Pugllohuma');
309
310 });
311
312
313 Class_10_Chart.onClick(function(xValue, yValue, seriesName) {
314   if (!xValue) return; // Selection was cleared.
315
316   // Show the image for the clicked date.
317   var equalDate = ee.Filter.equals('system:time_start', xValue);
318   //Find image coresponding with clicked data
319   var rfClass = ee.Image(classifiedD.filter(equalDate)
320     .first()).select('classification');
321   var ic = s2.map(function(image){
322     return image.set(
323       'dateDist',
324       ee.Number(image.get('system:time_start')).subtract(rfClass
325         .get('system:time_start')).abs()
326     );
327   });
328   ic = ic.sort('dateDist');

```

```

329     var S2NDVI = ee.Image(ic.first()).select('NDVI');
330     var S2NDWI = ee.Image(ic.first()).select('NDWI');
331     //Make map layer based on SAR image, reset the map layers,
332     // and add this new layer
333     var S1Layer = ui.Map.Layer(rfClass, {
334         max: 12,
335         min: 10,
336         palette: ['#2007ab','#70dcbe','#38ad1b']
337     },'SAR Classification');
338     map.layers().reset([S1Layer]);
339     var waterPalette = ['red', 'yellow', 'green', 'blue'];
340     map.addLayer(S2NDWI, {min: -1, max: 1, palette: waterPalette},
341     'NDWI');
342     var vegetationPalette = ['blue', 'white', 'green'];
343     map.addLayer(S2NDVI, {min: -1, max: 1, palette: vegetationPalette},
344     'NDVI');
345     // Show a label with the date on the map.
346     label.setValue((new Date(xValue)).toUTCString());
347
348 //Map aguas_abiertas
349 //map.addLayer(aguas_abiertas, {color: 'white'} , 'Aguas abiertas');
350 map.addLayer(hp, {}, 'Humedal Pugllahoma');
351
352     });
353
354 Class_12_Chart.onClick(function(xValue, yValue, seriesName) {
355     if (!xValue) return; // Selection was cleared.
356
357     // Show the image for the clicked date.
358     var equalDate = ee.Filter.equals('system:time_start', xValue);
359     //Find image coresponding with clicked data
360     var rfClass = ee.Image(classifiedD.filter(equalDate)
361     .first()).select('classification');
362     var ic = s2.map(function(image){
363     return image.set(
364     'dateDist',
365     ee.Number(image.get('system:time_start')).subtract(rfClass
366     .get('system:time_start')).abs()
367     );
368     });
369     ic = ic.sort('dateDist');
370     var S2NDVI = ee.Image(ic.first()).select('NDVI');
371     var S2NDWI = ee.Image(ic.first()).select('NDWI');
372     //Make map layer based on SAR image, reset the map layers,
373     // and add this new layer
374     var S1Layer = ui.Map.Layer(rfClass, {
375         max: 12,
376         min: 10,
377         palette: ['#2007ab','#70dcbe','#38ad1b']
378     },'SAR Classification');
379     map.layers().reset([S1Layer]);
380     var waterPalette = ['red', 'yellow', 'green', 'blue'];
381     map.addLayer(S2NDWI, {min: -1, max: 1, palette: waterPalette},
382     'NDWI');
383     var vegetationPalette = ['blue', 'white', 'green'];
384     map.addLayer(S2NDVI, {min: -1, max: 1, palette: vegetationPalette},
385     'NDVI');
386     // Show a label with the date on the map.
387     label.setValue((new Date(xValue)).toUTCString());
388
389 //Map aguas_abiertas
390 //map.addLayer(aguas_abiertas, {color: 'white'} , 'Aguas abiertas');
391 map.addLayer(hp, {}, 'Humedal Pugllahoma');
392
393     });
394
395 //ADD A LEGEND FOR BOTH NDVI AND NDWI
396 // set position of panel

```

```

397 var NDVIlegend = ui.Panel({
398   style: {
399     position: 'middle-right',
400     padding: '8px 15px'
401   }
402 });
403
404 var NDWIlegend = ui.Panel({
405   style: {
406     position: 'middle-left',
407     padding: '8px 15px'
408   }
409 });
410
411 // Create legend title
412 var NDVIlegendTitle = ui.Label({
413   value: 'NDVI LEGEND',
414   style: {
415     fontWeight: 'bold',
416     fontSize: '18px',
417     margin: '0 0 4px 0',
418     padding: '0'
419   }
420 });
421
422 var NDWIlegendTitle = ui.Label({
423   value: 'NDWI LEGEND',
424   style: {
425     fontWeight: 'bold',
426     fontSize: '18px',
427     margin: '0 0 4px 0',
428     padding: '0'
429   }
430 });
431
432 // Add the title to the panel
433 NDVIlegend.add(NDVIlegendTitle);
434 NDWIlegend.add(NDWIlegendTitle);
435
436 // Creates and styles 1 row of the legend.
437 var makeRow = function(color, name) {
438
439   // Create the label that is actually the colored box.
440   var colorBox = ui.Label({
441     style: {
442       backgroundColor: '#' + color,
443       // Use padding to give the box height and width.
444       padding: '8px',
445       margin: '0 0 4px 0'
446     }
447   });
448
449   // Create the label filled with the description text.
450   var description = ui.Label({
451     value: name,
452     style: {margin: '0 0 4px 6px'}
453   });
454
455   // return the panel
456   return ui.Panel({
457     widgets: [colorBox, description],
458     layout: ui.Panel.Layout.Flow('horizontal')
459   });
460 };
461
462 // Palette with the colors
463 var NDVIpalette = ['1500ff', 'FFFFFF', '22ff00'];
464 var NDWIpalette = ['FF0000', 'f4c20d', '22ff00', '1500ff'];

```

```

465
466 // name of the legend
467 var NDVINames = ['Vegetation free region',
468   'Bush and meadow vegetation',
469   'Forests of temperate climate and tropical rainforests'];
470 var NDWINames = ['Low humidity','Slight humidity','Flooded Vegetation','Water'];
471
472 // Add color and and names
473 for (var i = 0; i < 3; i++) {
474   NDVIlegend.add(makeRow(NDVIpalette[i], NDVINames[i]));
475 }
476
477 for (var j = 0; j < 4; j++) {
478   NDWIlegend.add(makeRow(NDWIpalette[j], NDWINames[j]));
479 }
480
481
482
483 // Create a confusion matrix representing resubstitution accuracy.
484 print('RF error matrix: ', classifier.confusionMatrix());
485 print('RF accuracy: ', classifier.confusionMatrix().accuracy());
486
487 //Map AOI and Zoom area
488 //map.addLayer(AOI, {}, 'AOI');
489 map.centerObject(AOI, 15.3); //Specify the zoom magnitude
490
491 //Map Pozos
492 map.addLayer(wells, {color: 'white'} , 'Pozos');
493 //Drenaje
494 map.addLayer(drain, {color: '#2fced6'} , 'Drenaje');
495 //Carretera
496 map.addLayer(roads, {color: '#999900'} , 'Carretera');
497
498
499 //#####
500 //##### ADD PANELS TO INTERFACE #####
501 //#####
502
503 controlPanel.add(NDVIlegend);
504 controlPanel.add(NDWIlegend);
505 controlPanel.add(paramPanel);
506
507 plotPanelParent.add(Class_10_Chart);
508 plotPanelParent.add(Class_11_Chart);
509 plotPanelParent.add(Class_12_Chart);
510
511 ui.root.clear();
512 ui.root.add(controlPanel);
513 ui.root.add(map);
514 ui.root.add(plotPanelParent);

```

## **ANEXO 7**

### **Script de evaluación espacial**

```

1  #####
2  #####
3  // # ESCUELA POLITÉCNICA #\
4  NACIONAL #\
5  // # FACULTAD DE INGENIERÍA CIVIL Y #\
6  AMBIENTAL #\
7  // # PIJ 17 - #\
8  05 #\
9  #####
10 #####
11
12 // CREATION DATE: //03/06/2020
13 // AUTHOR: DAVID CARCHIPULLA | cmorales.david@outlook.com
14 // Environmental Engineering Thesis
15 // LAST UPDATE: 08/07/2020
16
17 // Importing Shapefiles, DEM, and slope tiff
18 var AOI = ee.FeatureCollection("users/PIJ-17-05/wetland_bff_500m");
19 var drain = ee.FeatureCollection("users/PIJ-17-05/drain_bff10m");
20 var wells = ee.FeatureCollection('users/PIJ-17-05/wells_bff10m');
21 var roads = ee.FeatureCollection('users/PIJ-17-05/roads_w');
22 var dem = ee.Image("users/PIJ-17-05/dem_antisana");
23 var slp = ee.Image("users/PIJ-17-05/slp_antisana");
24 var hp = ee.FeatureCollection('users/PIJ-17-05/Humedal_Pugllohuma7');
25 var spatialClass = ee.FeatureCollection('users/PIJ-17-05/class_dissolve');
26
27 // map panel
28 var map = ui.Map();
29 map.setOptions('HYBRID');
30
31 // Load Sentinel-1 SAR collection and filter according to data
32 // collection type
33 var s1 = ee.ImageCollection('COPERNICUS/S1_GRD')
34 .filterBounds(AOI)
35 .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
36 .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
37 .filterMetadata('resolution_meters', 'equals', 10);
38
39 // Filter speckle noise
40 var filterSpeckles = function(img) {
41   var vv = img.select('VV'); //select the VV polarization band
42   var vh = img.select('VH');
43   var vv_smoothed = vv.focal_median(30, 'circle', 'meters'); //Apply a focal median
44   // filter
45   var vh_smoothed = vh.focal_median(30, 'circle', 'meters'); //Apply a focal median
46   // filter
47   var smoothed = ee.Image.cat(vv_smoothed, vh_smoothed)
48   .rename(['VV_S', 'VH_S']);
49   return img.addBands(smoothed); // Add filtered VV band to original image
50 };
51 s1=s1.map(filterSpeckles);
52 print(s1);
53
54 // Adding Polarimetric Indexes
55
56 // Function to compute and add polarization indexes as bands
57 // as well as, day of the year; slope; and elevation data
58 var addindexes = function(ima) {
59   var VV = ima.select('VV_S');
60   var VH = ima.select('VH_S');
61   var NDPI = VV.subtract(VH).divide(VV.add(VH));
62   var NVHI = VH.divide(VV.add(VH));
63   var NVVI = VV.divide(VV.add(VH));
64   var VVrVH = VH.divide(VV);
65
66   var doy = ima.date().getRelative('day', 'year');

```

```

61     var doyBand = ee.Image.constant(doy).uint16().rename('doy');
62
63     var recipe = ee.Image.cat(NDPI, NVHI, NVVI, VhrVV, doyBand, dem, slp)
64       .rename(['NDPI', 'NVHI', 'NVVI', 'VhrVV', 'DOY', 'DEM', 'slp']);
65     return ima.addBands(recipe);
66   };
67
68   // Add index bands to image collection
69   s1 = s1.map(addindexes);
70
71   // set a date property to exactly 00:00 AM
72   // Also, S1 images were clipped by the AOI
73   s1 = s1.map(function(image){
74     return image.set('simpleTime', ee.Date(image.date()
75       .format('YYYY-MM-dd')).millis()).clip(AOI);
76   });
77
78
79   //////////// Load Sentinel-2 collection and filter according to data collection type
80   /**
81    * Function to mask clouds using the Sentinel-2 QA band
82    * @param {ee.Image} image Sentinel-2 image
83    * @return {ee.Image} cloud masked Sentinel-2 image
84    */
85   function maskS2clouds(image) {
86     var QA = image.select('QA60');
87
88     // Bits 10 and 11 are clouds and cirrus, respectively.
89     var cirrus = QA.bitwiseAnd(Math.pow(2, 11)).eq(0);
90     var cloud = QA.bitwiseAnd(Math.pow(2, 10)).eq(0);
91
92     return image.updateMask(cirrus).updateMask(cloud);
93   }
94
95   //Load Sentinel-2 collection and filter according to data collection type
96   var s2 = ee.ImageCollection('COPERNICUS/S2')
97     .filterBounds(hp)
98     .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less_than', 60)
99     .map(maskS2clouds);
100
101   // Function to compute and add NDVI, as well as, NDWI
102   var addS2indexes = function(ima) {
103     var NDVI=ima.normalizedDifference(['B8', 'B4']);
104     var MNDWI=ima.normalizedDifference(['B3', 'B11']);
105
106     var doy = ima.date().getRelative('day', 'year');
107     var doyBand = ee.Image.constant(doy).uint16().rename('doy');
108
109     var indexes= ee.Image.cat(NDVI, MNDWI, doy, slp)
110       .rename(['NDVI', 'MNDWI', 'DOY', 'slp']);
111     return ima.addBands(indexes);
112   };
113
114   // Add index bands to image collection
115   s2 = s2.map(addS2indexes);
116
117   // set a date property to exactly 00:00 AM
118   // Also, S1 images were clipped by the AOI
119   s2 = s2.map(function(image){
120     return image.set('simpleTime', ee.Date(image.date()
121       .format('YYYY-MM-dd')).millis()).clip(AOI);
122   });
123
124
125   //////////// Filtering by assessing dates
126
127   ///Importing classified dates
128   var s1Dates = ee.List(['2017-06-05', '2017-07-13', '2017-08-18', '2017-09-21',

```

```

129             '2017-10-17','2017-12-16','2018-01-09',//'2018-07-18',
130             '2018-08-25','2018-10-24','2018-12-23','2019-02-15'})
131             .map(function(date){return ee.Date(date).millis()});
132 //S2 showed an atypical behavior on '2018-07-16', then this date is discarded
133 var s2Dates = ee.List(['2017-06-06','2017-07-16','2017-08-20','2017-09-19',
134             '2017-10-19','2017-12-18','2018-01-07',//'2018-07-16',
135             '2018-08-25','2018-10-24','2018-12-23','2019-02-16'])
136             .map(function(date){return ee.Date(date).millis()});
137
138 //Applying date filter
139 s1 = s1.filter(ee.Filter.inList("simpleTime", s1Dates));
140 print(s1); // Saturation Dates
141
142 s2 = s2.filter(ee.Filter.inList("simpleTime", s2Dates));
143 print(s2); // Saturation Dates
144
145
146 //////////////// Classification sentinel 1
147 // Reshaped sample is imported to GEE
148 var ClassSample = ee.FeatureCollection("users/PIJ-17-05/ClassSample");
149
150 // Needed variables are established
151 var bands = ['DEM','DOY','VH_S','VV_S','angle','slp'];
152
153 // Classifier is trained
154 // 800 decision trees are needed
155 var classifier = ee.Classifier.randomForest(100).train({
156     features: ClassSample,
157     classProperty: 'landcover',
158     inputProperties: bands // Not all variables are needed,
159     }); // Just those included in bands
160
161 // Classification is implemented in s1
162 // s1 includes all images provided by GEE
163 // and it already has computed polarimetric indexes
164
165 var rfModel = function(classifying) {
166     var classified = classifying.select(bands).classify(classifier);
167     return classifying.addBands(classified);
168 };
169 var s1Classified = s1.map(rfModel);
170 print(s1Classified);
171
172 // Classes are selected and added to the image as new bands
173 // It is needed to visualize spatial classification
174 var add_class = function(imgs1) {
175     var class_band = imgs1.select('classification');
176     var ss = class_band.eq(10); //Identify classified pixels
177     var ws = class_band.eq(11); // and set them equal to 1.
178     var ds = class_band.eq(12); // All other pixels set to 0
179     ss = ss.updateMask(ss); //Remove all pixels equal to 0
180     ws = ws.updateMask(ws); //Remove all pixels equal to 0
181     ds = ds.updateMask(ds); //Remove all pixels equal to 0
182     var class_bands = ee.Image.cat(ss, ws, ds)
183     .rename(['Saturated','Wet','Dry']);
184     return imgs1.addBands(class_bands);
185 };
186
187 //Map classification across sentinel-1 collection and print to console to inspect
188 s1Classified = s1Classified.map(add_class);
189 print(s1Classified);
190
191
192 //////////////// Classification sentinel 2
193 // Reshaped sample is imported to GEE
194 var S2Sample = ee.FeatureCollection("users/PIJ-17-05/S2Sample");
195
196 // Classification is implemented in s2

```



```

197 // s2 includes all images provided by GEE
198 // and it already has computed spectral indexes
199
200 var kmeansmodel = function(classifyingS2) {
201
202   // Make the training dataset.
203   var training = classifyingS2.select('MNDWI','NDVI','DOY','slp').sample({
204     region: spatialClass,
205     scale: 10
206   });
207
208   // Instantiate the clusterer and train it.
209   var clusterer = ee.Clusterer.wekaKMeans(3).train(training);
210
211   var classifiedS2 =
212     classifyingS2.select('MNDWI','NDVI','DOY','slp').cluster(clusterer);
213   return classifyingS2.addBands(classifiedS2);
214 };
215 var s2Classified = s2.map(kmeansmodel);
216 print(s2Classified);
217
218 // Classes are selected and added to the image as new bands
219 // It is needed to visualize spatial classification
220 var add_class_s2 = function(imgs2) {
221   var class_band_s2 = imgs2.select('cluster');
222   var ss2 = class_band_s2.eq(0); //Identify classified pixels
223   var ws2 = class_band_s2.eq(1); // and set them equal to 1.
224   var ds2 = class_band_s2.eq(2); // All other pixels set to 0
225   ss2 = ss2.updateMask(ss2); //Remove all pixels equal to 0
226   ws2 = ws2.updateMask(ws2); //Remove all pixels equal to 0
227   ds2 = ds2.updateMask(ds2); //Remove all pixels equal to 0
228   var class_bands_s2 = ee.Image.cat(ss2, ws2, ds2)
229     .rename(['Saturated','Wet','Dry']);
230   return imgs2.addBands(class_bands_s2);
231 };
232
233 //Map classification across sentinel-1 collection and print to console to inspect
234 s2Classified = s2Classified.map(add_class_s2);
235 print(s2Classified);
236
237 //Make time series of pixels within region
238 var S1_Chart = ui.Chart.image.series({
239   imageCollection: s1Classified.select(['Saturated','Wet','Dry']),
240   region: AOI,
241   reducer: ee.Reducer.sum(),
242   scale:100
243 });
244 .setOptions({
245   title: 'S1 Classified Pixels',
246   hAxis: {'title': 'Date'},
247   vAxis: {'title': 'Ha of Inundated'},
248   lineWidth: 2,
249   series: {
250     0: {color: '#38ad1b'}, // Dry
251     2: {color: '#70dcbe'}, // Wet
252     1: {color: '#2007ab'} // Saturated
253   }
254 });
255
256 //Set the position of the chart and add it to the map
257 S1_Chart.style().set({
258   position: 'bottom-right',
259   width: '500px',
260   height: '300px'
261 });
262
263 var S2_Chart = ui.Chart.image.series({
264   imageCollection: s2Classified.select(['Dry','Wet','Saturated']),

```

```

264     region: AOI,
265     reducer: ee.Reducer.sum(),
266     scale:100
267   })
268   .setOptions({
269     title: 'S2 Classified Pixels',
270     hAxis: {'title': 'Date'},
271     vAxis: {'title': 'Ha of class'},
272     lineWidth: 2,
273     series: {
274       0: {color: '#38ad1b'}, // Dry
275       2: {color: '#70dcbe'}, // Wet
276       1: {color: '#2007ab'} // Saturated
277     }
278   });
279
280 //Set the position of the chart and add it to the map
281 S2_Chart.style().set({
282   position: 'bottom-left',
283   width: '500px',
284   height: '300px'
285 });
286
287 // Create a label on the map.
288 var labelS1 = ui.Label({
289   value: 'Click a point on the right chart to show the image for that date.',
290   style: {position: 'top-center'}
291 });
292 map.add(labelS1);
293
294 var labelS2 = ui.Label({
295   value: 'Click a point on the left chart to show the image for that date.',
296   style: {position: 'bottom-center'}
297 });
298 map.add(labelS2);
299
300 //Create callback function that adds image to the map corresponding with clicked data
point on chart
301 S1_Chart.onClick(function(xValue, yValue, seriesName) {
302   if (!xValue) return; // Selection was cleared.
303
304   // Show the image for the clicked date.
305   var equalDate = ee.Filter.equals('system:time_start', xValue);
306   //Find image corresponding with clicked data
307   var rfClass = ee.Image(s1Classified.filter(equalDate)
308     .first()).select('classification');
309   //Make map layer based on SAR image, reset the map layers,
310   // and add this new layer
311   var S1Layer = ui.Map.Layer(rfClass, {
312     max: 12,
313     min: 10,
314     palette: ['#2007ab', '#70dcbe', '#38ad1b']
315   }, 'SAR Classification');
316   map.layers().reset([S1Layer]);
317   // Show a label with the date on the map.
318   labelS1.setValue((new Date(xValue)).toUTCString());
319
320
321 //Map aguas_abiertas
322 //map.addLayer(aguas_abiertas, {color: 'white'} , 'Aguas abiertas');
323 map.addLayer(hp, {}, 'Humedal Puglllohuma');
324
325   });
326
327
328 //Create callback function that adds image to the map corresponding with clicked data
point on chart
329 S2_Chart.onClick(function(xValue, yValue, seriesName) {

```

```

330     if (!xValue) return; // Selection was cleared.
331
332     // Show the image for the clicked date.
333     var equalDate = ee.Filter.equals('system:time_start', xValue);
334     //Find image corresponding with clicked data
335     var kmClass = ee.Image(s2Classified.filter(equalDate)
336         .first()).select('cluster');
337     //Make map layer based on cluster classification,
338     // and add this new layer
339     map.addLayer(kmClass,{
340         max: 2,
341         min: 0,
342         palette: ['#2007ab','#70dcbe','#38ad1b']
343     },'Spectral Classification');
344     // Show a label with the date on the map.
345     labels2.setValue((new Date(xValue)).toUTCString());
346
347
348 //Map aguas_abiertas
349 //map.addLayer(aguas_abiertas, {color: 'white'} , 'Aguas abiertas');
350 });
351 //Customizing map
352 ui.root.clear();
353 ui.root.add(map);
354
355 //Map AOI and Zoom area
356 //map.addLayer(AOI, {}, 'AOI');
357 map.centerObject(AOI, 15.3); //Specify the zoom magnitude
358
359
360 //Adding charts
361 map.add(S1_Chart);
362 map.add(S2_Chart);
363
364
365
366
367 //First date analysis
368 var listOfImages = s2.toList(s2.size());
369 var selection = listOfImages.get(5); //select the image you want to plot
370 var S2_selection = ee.Image(selection);
371 print(S2_selection);
372 // Pre-define some customization options.
373 var options = {
374     title: 'Sentinel 2 histogram',
375     fontSize: 20,
376     hAxis: {title: 'spectrum'},
377     vAxis: {title: 'count of distribution'}};
378
379 // Make the histogram, set the options.
380 var histogram = ui.Chart.image.histogram(S2_selection, AOI, 30)
381     .setOptions(options);
382
383 // Display the histogram.
384 print(histogram);

```

## **ANEXO 8**

**Registro fotográfico del humedal Pugllohuma**



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 29 de noviembre de 2019).

Campo 1. Coordenadas:  
-0.502223,-78.214027



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 29 de noviembre de 2019).

Campo 2. Coordenadas:  
-0.501328,-78.214425



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 07 de enero de 2020).

Campo 3. Coordenadas:  
-0.500758,-78.213666



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 07 de enero de 2020).

Campo 3. Coordenadas:  
-0.500752,-78.213667



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 07 de enero de 2020).

Campo 3.  
Coordenadas:  
-0.5006818,-78.21367



[Fotografía de David Carchipulla]. (Reserva Ecológica Antisana, 07 de enero de 2020).

Campo 3.  
Coordenadas:  
-0.501323,-78.213832